

การแก้ปัญหาการจัดเรียงลำดับเบสทัลายลำดับโดยขั้นตอนวิธีเชิงวิจัย

นายพศุตม์ สีเหลืองสวัสดิ์

ศูนย์วิทยทรัพยากร จุฬาลงกรณ์มหาวิทยาลัย

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมคอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2547

ISBN 974-17-7100-2

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

MULTIPLE SEQUENCE ALIGNMENT USING EVOLUTIONARY ALGORITHMS

Mr. Pasut Seeluangsawat

ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย

A Thesis Submitted in Partial Fulfillment of the Requirements

for the Degree of Master of Engineering in Computer Engineering

Department of Computer Engineering

Faculty of Engineering

Chulalongkorn University

Academic Year 2004

ISBN 974-17-7100-2

หัวข้อวิทยานิพนธ์

การแก้ปัญหาการจัดเรียงลำดับเบสหน่วยลำดับโดยขั้นตอนวิธีเชิงวิวัฒน์

၆၈

นายพศุตม์ สีเหลืองสวัสดิ์

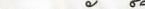
สาขาวิชา

วิศวกรรมคอมพิวเตอร์

อาจารย์ที่ปรึกษา

รองศาสตราจารย์ ดร.ประภาส ใจสุกิตย์วัฒนา

คณวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้บัณฑิตวิทยานิพนธ์ฉบับนี้
เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาบัณฑิต

  คณบดีคณวิศวกรรมศาสตร์
(ศาสตราจารย์ ดร. ดิลก ไวยนัยศรี)
(ศาสตราจารย์ ดร. ชิตพัฒน์ ชิตพัฒน์)

คณะกรรมการสอบวิทยานิพนธ์

ประชานกรรมการ

ស្រុក ១៩ សាកលវិទ្យាល័យ ភ្នំពេញ

(รองศาสตราจารย์ ดร.ประภาส วงศิตย์วัฒนา)

..... กรุณากรอก
(อาจารย์ ดร.วิชณุ โคตรจรัส)

(อาจารย์ ดร.วิชณุ คงครจรัล)

សាខា ពិសោធន៍អំពីការរៀបចំក្រសួង: ក្រសួងការ
(ដើម្បីថ្លែងការណ៍សាខាសាស្ត្រទ្វាជារម្ម ជន នាមខែ ខ្លួយវត្ថុនេះ)

พศุตม์ สีเหลืองสวัสดิ์ : การแก้ปัญหาการจัดเรียงลำดับเบสหดลายลำดับโดยขั้นตอนวิธีเชิงวิวัฒน์
 (MULTIPLE SEQUENCE ALIGNMENT USING EVOLUTIONARY ALGORITHMS) อ. ที่
 ปรึกษา : วศ.ดร.ประภาส วงศิตย์วัฒนา, 64หน้า. ISBN 974-17-7100-2.

ปัญหาการจัดเรียงลำดับเบสหดลายลำดับเป็นปัญหาที่สำคัญทางด้านชีวสารสนเทศศาสตร์
 ซึ่งปัญหานี้มีการศึกษาค้นคว้าอย่างแพร่หลาย และมีเครื่องมือสำหรับแก้ปัญหามากมาย
 วิทยานิพนธ์นี้นำเสนอการแก้ปัญหาการจัดเรียงลำดับเบสหดลายลำดับโดยขั้นตอนวิธีเชิงวิวัฒน์
 แบบหดลายวัตถุประสงค์ เพื่อพัฒนาคำตออบจากโปรแกรมสำหรับการแก้ปัญหาระดับเรียงลำดับ
 เบสหดลายลำดับ โดยผลเฉลยเริ่มต้นของงานวิจัยนี้มาจากการโปรแกรม Clustal W, Dialign, MFFT
 และ T-Coffee

งานวิจัยนี้ทำการทดสอบโดยใช้ชุดข้อมูลจากฐานข้อมูล BALiBASE และผลการทดลองที่
 ได้จะทำการเปรียบเทียบคำตออบกับโปรแกรมที่มีอยู่ ผลเปรียบเทียบการทดลองแสดงให้เห็นว่าค่า
 ความถูกต้องของคำตออบที่ได้มีการพัฒนาขึ้นอยู่อย่างเห็นได้ชัด

ศูนย์วิทยทรัพยากร จุฬาลงกรณ์มหาวิทยาลัย

ภาควิชา.... วิศวกรรมคอมพิวเตอร์..... ลายมือชื่อนิสิต..... กฤต พันธุ์รุ่ง
 สาขาวิชา.... วิศวกรรมคอมพิวเตอร์..... ลายมือชื่ออาจารย์ที่ปรึกษา..... ดร.นว ใจสกุลชัยชนะ
 ปีการศึกษา 2547

4670403421 : MAJOR Computer Engineering

KEY WORD: MULTIPLE SEQUENCE ALIGNMENT / EVOLUTIONARY ALGORITHM

PASUT SEELUANGSAWAT : MULTIPLE SEQUENCE ALIGNMENT USING
EVOLUTIONARY ALGORITHMS. THESIS ADVISOR : ASSOC. PROF. PRABHAS
CHONGSTITVATANA, 64 pp. ISBN 974-17-7100-2.

The problem of multiple sequence alignment is important for bioinformatics. This problem is widely studied and there are many popular tools to solve this problem. This thesis introduces a multiple objective evolutionary algorithm to improve solutions obtained from existing tools. An initial solution for the proposed algorithm is derived from Clustal W, Dialign, MFFT and T-Coffee.

The proposed algorithm is tested with the dataset from BALiBASE database. The experiments are conducted to compare the results from the proposed algorithm against the results from existing algorithms. The comparison shows a clear improvement in terms of correctness of the results.

ศูนย์วิทยทรัพยากร จุฬาลงกรณ์มหาวิทยาลัย

Department.... Computer Engineering.... Student's signature.....*Pasut S.*
Field of study.... Computer Engineering... Advisor's signature.....*P. Chongstitvatan*
Academic year ...2004.....

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้ด้วยความช่วยเหลือ และความกรุณาจาก รศ.ดร. ประภาส ใจสุกิตย์วัฒนา อาจารย์ที่ปรึกษาวิทยานิพนธ์ อันเป็นผู้ให้คำปรึกษา และคูเลในการทำวิจัยให้กับข้าพเจ้าเสมอมา

ขอขอบคุณเพื่อน พี่ และ น้องนักศึกษาปริญญาโททุกท่านที่ให้กำลังใจ และร่วมทุกๆร่วมสุขกันมาตลอด

ท้ายที่สุดขอกราบขอบพระคุณพ่อ คุณแม่ผู้ให้กำเนิด รวมทั้งพี่ชาย ที่เคยสนับสนุน ดูแล และให้กำลังใจข้าพเจ้าควบคู่กันนี้

ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย

สารบัญ

หน้า

บทคัดย่อภาษาไทย	๑
บทคัดย่อภาษาอังกฤษ	๑
กิตติกรรมประกาศ	๒
สารบัญ	๓
สารบัญภาพ	๔
สารบัญตาราง	๕
บทที่	
1 บทนำ	๑
1.1 ความเป็นมาและความสำคัญของปัญหา	๑
1.2 วัตถุประสงค์	๒
1.3 ขอบเขตงานวิจัย	๒
1.4 ขั้นตอนและวิธีดำเนินงานวิจัย	๒
1.5 ประโยชน์ที่คาดว่าจะได้รับ	๓
1.6 ผลงานที่ตีพิมพ์จากวิทยานิพนธ์	๓
2 ทฤษฎีที่เกี่ยวข้อง	๔
2.1 ความเป็นมาเกี่ยวกับสายพันธุกรรม	๔
2.2 ชีวสารสนเทศศาสตร์ (Bioinformatics)	๕
2.2.1 ช่วงเริ่มต้นของชีวสารสนเทศศาสตร์	๖
2.2.2 ช่วงก่อนโครงการจีโนมมนุษย์เสร็จ	๖
2.2.3 ช่วงหลังโครงการจีโนมมนุษย์	๖
2.3 ดีเอ็นเอ อาร์เอ็นเอ และโปรตีน	๘
2.3.1 องค์ประกอบและโครงสร้างของดีเอ็นเอ	๘
2.3.1.1 องค์ประกอบทางเคมีของดีเอ็นเอ	๙
2.3.1.2 โครงสร้างของดีเอ็นเอ	๑๐
2.3.1.3 หน้าที่ของดีเอ็นเอ	๑๐
2.3.1.4 ความแตกต่างของดีเอ็นเอ	๑๐
2.3.2 องค์ประกอบและโครงสร้างของอาร์เอ็นเอ	๑๒
2.3.3 องค์ประกอบและโครงสร้างของโปรตีน	๑๓

สารบัญ(ต่อ)

	หน้า
2.4 ปัญหาการจัดเรียงลำดับเบสหดลายลำดับ	15
2.4.1 รูปแบบข้อมูลที่ใช้กับปัญหา	15
2.4.2 คะแนนที่ใช้คำนวณความถูกต้อง	16
2.4.2.1 สมการผลรวมคู่เบส และตารางการแทน	16
2.4.2.2 วิธีการคำนวณหาเอ็นโทรปีต่ำสุด	17
2.4.2.3 การหักคะแนนเมื่อมีแก็ป	18
2.5 การแก้ปัญหาแบบหดลายวัตถุประสงค์ (Multiple objective optimization)	19
2.5.1 ทฤษฎีเบื้องต้นของการแก้ปัญหาแบบหดลายวัตถุประสงค์	19
2.6 ขั้นตอนวิธีเชิงวิวัฒน์ (Evolutionary Algorithm)	20
2.6.1 ขั้นตอนวิธีพันธุกรรม (Genetic Algorithms)	20
2.6.2 รายละเอียดของขั้นตอนวิธีเชิงพันธุกรรม	21
2.6.2.1 การสร้างกลุ่มประชากรของผลเฉลยตั้งต้น	21
2.6.2.2 การตรวจสอบค่าความแข็งแรงของผลเฉลย	22
2.6.2.3 การสร้างกลุ่มประชากรของผลเฉลยรุ่นใหม่	22
2.6.2.4 การค้นหาคำตอบ	23
3 งานวิจัยที่เกี่ยวข้อง	24
3.1 งานวิจัยเกี่ยวกับขั้นตอนวิธีเชิงวิวัฒน์แบบหดลายวัตถุประสงค์	24
3.1.1 แบบไม่ใช้พาราเมตอร์	24
3.1.2 แบบใช้พาราเมตอร์	25
3.2 งานวิจัยเกี่ยวกับการจัดเรียงลำดับเบสหดลายลำดับ	25
3.2.1 การใช้ขั้นตอนวิธีเชิงวิวัฒน์ในการแก้ปัญหา	25
3.2.2 การใช้ขั้นตอนวิธีต่างๆ	26
3.3 ตัวอย่างขั้นตอนวิธีในการแก้ไขปัญหาการจัดเรียงลำดับเบสหดลายลำดับ	27
3.3.1 การจัดเรียงองค์รวม (Global alignment)	27
3.3.2 Clustal W	29
3.3.3 MSA-EA2002	31
3.3.4 MSA-EA2003	35
3.4 ฐานข้อมูล BALiBASE	38
4 รายละเอียดงานวิจัย	41

สารบัญ(ต่อ)

	หน้า
4.1 ขั้นตอนวิธีโปรแกรม MOMSA	41
4.2 การเข้ารหัสปัญหา	42
4.3 การสร้างประชากรเริ่มต้น	43
4.4 การกำหนดพังก์ชันวัตถุประสงค์	43
4.5 การกำหนดลำดับที่	43
4.6 การคัดเลือกประชากรรุ่นถัดไป	44
4.7 การคัดเลือกผลเฉลยเพื่อปรับปรุง	45
4.8 การไขว้เปลี่ยน และการยกลายพันธุ์	45
4.8.1 การย้ายเบสแบบสุ่ม	45
4.8.2 การย้ายเบสแบบย้ายผู้	46
4.8.3 การเลื่อนแท่ง	46
4.8.4 การไขว้เปลี่ยนแบบสองจุด	47
4.9 การหาผลเฉลยสุดท้าย	47
4.10 พารามิเตอร์ใช้	48
5 การทดลอง	50
5.1 ข้อมูลที่ใช้ในการทดลอง	50
5.2 การคำนวณความถูกต้องของผลเฉลย	50
5.3 ผลการทดลอง	51
5.3.1 ผลการเปรียบเทียบระหว่างการใช้พังก์ชันวัตถุประสงค์เดียวกับการใช้ส่องพังก์ชันวัตถุประสงค์	51
5.3.2 ผลการเปรียบเทียบการใช้โปรแกรมต่างๆในการสร้างกลุ่มประชากร เริ่มต้นให้กับโปรแกรม MOMSA	53
6 สรุปผลการวิจัยและข้อเสนอแนะ	60
6.1 สรุปผลการวิจัย	60
6.2 ข้อเสนอแนะ	60
รายงานอ้างอิง	61
ประวัติผู้เขียนวิทยานิพนธ์	64

สารบัญภาพ

หน้า

รูปที่2.1 ตัวอย่างแสดง SNP	7
รูปที่2.2 องค์ประกอบของดีเอ็นเอ	8
รูปที่2.3 สายนิวคลีโอไทด์ที่เขื่อมด้วยพันธะฟอสฟोไดโอด์จากปลาย 5' ไปปลาย 3'	9
รูปที่2.4 โครงสร้างของดีเอ็นเอ	10
รูปที่2.5 การกลایพันธุ์บนสายดีเอ็นเอ	11
รูปที่2.6 การขาดหาย หรือการขยายจำนวนของดีเอ็นเอในกระบวนการไขว้เปลี่ยน	12
รูปที่2.7 การขยายจำนวนของดีเอ็นเอที่เกิดจากการเลื่อนของเบส	12
รูปที่2.8 หน้าที่ของอาร์เอ็นเอ	13
รูปที่2.9 โครงสร้างกรดอะมิโนทั้ง 20 ชนิด	14
รูปที่2.10 โครงสร้างโปรตีน	15
รูปที่2.11 ตัวอย่างข้อมูลรูปแบบเจ็มເຄົພຂອງຮັສກຣດອະມິນ	15
รูปที่2.12 ตัวอย่างลำดับເບສຫລາຍลำดับສໍາຮັບຄຳວຸນເຄືນໂກປີ	17
รูปที่2.13 ตัวอย่างการคำนวณการหักຄະແນນເມືອນິກຶບ	18
รูปที่2.14 กราฟแสดงປົມຫາແບບສອງວັດຖຸປະສົງຄົງ	19
รูปที่2.15 ຮັສເທີມຂອງຂັ້ນຕອນວິທີເຊິ່ງພັນຫຼຸກຮົມ	21
รูปที่2.16 แสดงตัวอย่างการกลایพันธุ์ຈາກຜລເຊລຍດັ່ນແບບ (ກ) ໄປເປັນຜລເຊລຍໃໝ່ (ຂ)	23
รูปที่2.17 ตัวอย่างการไขว้เปลี่ยน ຈາກຜລເຊລຍດັ່ນແບບ 2 ຜລເຊລຍ	23
รูปที่3.1 ຮັສເທີມຂອງຂັ້ນຕອນ Needleman-Wunsch.....	27
รูปที่3.2 ກາຮແກ້ປົມຫາໂດຍຂັ້ນຕອນ Needleman-Wunsch.....	28
รูปที่3.3 ແສດຕາຮາງຄ່າຮະຍະທາງ	29
รูปที่3.4 ແສດ Neighbor-joining tree	30
รูปที่3.5 ຍກຕັວຢ່າງສື່ລຳດັບແຮກທີ່ມີກາຈັດເຮື່ອງ	30
รูปที่3.6 ແສດກາຮສ້າງປະຈາກຂອງຜລເຊລຍຕັ້ງຕັ້ນ	32
รูปที่3.7 ແສດວິທີ LocalShuffle	32
รูปที่3.8 ແສດວິທີ GrowMatchedColumn	33
รูปที่3.9 ແສດວິທີ RecombineMatchedColumn	34
รูปที่3.10 ຮັສເທີມຂັ້ນຕອນວິທີຂອງ MSA-EA2002	35
รูปที่3.11 ຮັສເທີມຂັ້ນຕອນວິທີຂອງ MSA-EA2003	37

สารบัญภาพ(ต่อ)

	หน้า
รูปที่3.12 สารบบในฐานข้อมูล BALiBASE	38
รูปที่4.1 รหัสเที่ยมขั้นตอนวิธีของโปรแกรม MOMSA	42
รูปที่4.2 รูปการแก้ปัญหาที่มีฟังก์ชันวัตถุประสงค์สองค่า	44
รูปที่4.3 การสร้างประชากร และหน่วยเก็บถาวรรุ่นต่อไป	44
รูปที่4.4 แสดงการย้ายเบสแบบสุ่ม	45
รูปที่4.5 แสดงการย้ายเบสแบบย้ายผึ้ง	46
รูปที่4.6 แสดงการเลื่อนแท่ง	46
รูปที่4.7 แสดงการไขว้เปลี่ยนแบบสองจุด	47
รูปที่4.8 รูปการหาผลเฉลยสุดท้าย	48
รูปที่5.1 รหัสเที่ยมขั้นตอนวิธีของ SOMSA	51

**ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย**

สารบัญตาราง

	หน้า
ตารางที่ 3.1 แสดงลักษณะความยาวของกลุ่มลำดับอ้างอิงในแต่ละสารบบ.....	39
ตารางที่ 5.1 รายละเอียด 9 ชุดข้อมูลที่ใช้ในการทดลอง.....	50
ตารางที่ 5.2 เปรียบเทียบค่า SPS/CS ที่ได้จากโปรแกรม MOMSA, SOMSA1,..... SOMSA2.....	52
ตารางที่ 5.3 เปรียบเทียบค่าความถูกต้องของคำตอบระหว่างโปรแกรม Clustal W	
กับโปรแกรม MOMSA	53
ตารางที่ 5.4 เปรียบเทียบค่าความถูกต้องของคำตอบระหว่างโปรแกรม Dialign	
กับโปรแกรม MOMSA	54
ตารางที่ 5.5 เปรียบเทียบค่าความถูกต้องของคำตอบระหว่างโปรแกรม MAFFT	
version fft-n-1 กับโปรแกรม MOMSA	55
ตารางที่ 5.6 เปรียบเทียบค่าความถูกต้องของคำตอบระหว่างโปรแกรม MAFFT	
version fft-n-2 กับโปรแกรม MOMSA	56
ตารางที่ 5.7 เปรียบเทียบค่าความถูกต้องของคำตอบระหว่างโปรแกรม T-Coffee..... กับโปรแกรม MOMSA	57
ตารางที่ 5.8 แสดงผลที่ได้จากโปรแกรม MOMSA เมื่อ + คือคำตอบมีค่าดีขึ้น และ..... - คือคำตอบมีค่าเปล่ง.....	58
ตารางที่ 5.9 แสดงค่า SPS/CS ที่ได้จากโปรแกรม MOMSA	59

ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย