

Comparative sequence analysis and association mining in gene regulation

Christoph Dieterich

August 2004

Dissertation zur Erlangung des Grades
eines Doktors der Naturwissenschaften (Dr. rer. nat)
am Fachbereich Mathematik und Informatik
der Freien Universität Berlin

1. Betreuer: Prof. Dr. Martin Vingron
2. Betreuer: Prof. Dr. Stefan Mundlos

Datum der Disputation: 04. März 2005

Für Silke, Eva und Joschua

Contents

1 Motivation	1
1.1 Thesis structure	2
1.2 Acknowledgments	2
2 Molecular biology of gene regulation	5
2.1 Genome biology	5
2.1.1 DNA - the carrier of genetic information	6
2.1.2 Genes - entities of genetic information	8
2.1.3 Strategies for gene detection	10
2.2 Gene regulation at the promotor level	10
2.2.1 Transcriptional control – DNA sequence elements	12
2.2.2 Transcription factors - protein components of gene regulation . .	13
2.2.3 Activating transcription - mechanistic insights	13
2.3 Conservation of genes and their regulation	14
2.3.1 Phylogenetic footprinting	16
2.4 Selected experimental approaches	17
2.4.1 Sensitive and accurate detection of gene expression – RT-PCR .	17
2.4.2 Large-scale measuring of gene expression levels with microarray technology	19
2.4.3 Chromatin immuno-precipitation	21
3 Comparative Sequence Analysis	23
3.1 Sequence Alignment	23
3.1.1 Global vs. Local sequence alignment	24
3.1.2 Models of nucleotide substitution	24
3.1.3 How to score an alignment.	27
3.1.4 Alignment algorithms	28
3.1.5 The Waterman-Eggert algorithm	30
3.2 Alignment statistics	31
3.2.1 Ungapped alignment statistics	31
3.2.2 Gapped alignment statistics	33
3.3 Multiple alignments	34

4 CORG - a promoter annotation framework	37
4.1 Definition of an upstream region	37
4.2 Sequence retrieval and preprocessing	38
4.2.1 Phylogenetic relationships of genes	38
4.2.2 Initial sequence processing	40
4.3 The notion of conserved non-coding blocks	41
4.3.1 Adaptation of the SIM implementation of the Waterman-Eggert algorithm.	42
4.3.2 Detection of CNBs	42
4.3.3 Extension to multi-species comparison	44
4.3.4 Annotation of conserved non-coding blocks and promoter regions	46
4.3.5 CORG pipeline	49
4.4 Database design	49
4.5 Web interface	49
4.6 CORG content summary	53
4.6.1 GC content and upstream region length	53
4.6.2 Conservation extent and localization	53
5 Applications for CORG	59
5.1 Binding site distributions across cell cycle phases	59
5.1.1 Binding site prediction	60
5.1.2 Association mining	61
5.1.3 Significant deviant binding site distributions	65
5.1.4 Biological implications	67
5.2 Promoter analysis of SRF responsive genes	68
5.2.1 Identification of SRF target genes	69
5.2.2 Experimental Validation of SRF-regulated genes by RT-PCR and ChIP	76
5.3 Comparison to the LPS response of dendritic cells.	78
5.3.1 Studying the LPS response of dendritic cells	78
5.3.2 Comparison of target gene sets	79
6 Conclusion	83
A Kurzzusammenfassung	97
B Erklärung zur Urheberschaft	99
C List of related publications	101
D Curriculum vitae	103

E Availability	105
E.1 The modified SIM implementation	105
E.2 Other software	105
E.3 CORG Database	105
F IUPAC nucleotide ambiguity codes	107

List of Figures

2.1	Structural organization of the genome	6
2.2	Schematic view of DNA structure and building blocks	7
2.3	From genes to proteins	9
2.4	Proximal promotor-level events	11
2.5	The helix-turn-helix DNA binding motif	14
2.6	Definition of orthologs and paralogs	15
2.7	Concept of phylogenetic footprinting	16
2.8	Schematic overview of the Polymerase Chain Reaction steps	18
2.9	Microarray technology	20
3.1	Chromosomal rearrangements	25
4.1	Distance distribution of transcription start to translation start	39
4.2	Phylogenetic footprinting in the promoter region of CKM	41
4.3	Random alignment scores and linear regression analysis	43
4.4	CORG multiple alignment building	45
4.5	CORG pipeline workflow	50
4.6	CORG Database schema	51
4.7	JAVA technology based web interface to CORG	52
4.8	GC content of promoter regions in five different species	54
4.9	Length distribution of upstream regions	55
4.10	Joint density distributions of repeat and conservation content for human upstream regions	56
4.11	Alignment localization comparison of man to four species.	57
5.1	Mitotic cell cycle	61
5.2	p-values for conserved predicted binding site distributions	64
5.3	Normalized association matrices.	67
5.4	RT-PCR confirmation of SRF-regulated genes	76
5.5	In-vivo SRF target validation by ChIP	77
5.6	Schematic overview of signalling via TLR4 receptor	81
5.7	Target predictions for the 5 principal transcription factor complexes involved in the LPS response	82
5.8	Slice of promoter region of IER3	82
5.9	Slice of promoter region of JUNB	82

List of Tables

2.1 Examples of promoter sequence elements	13
3.1 Models of nucleotide substitution	26
4.1 Wasserman et al. dataset, Man-rodent promoter comparison	40
4.2 Program workflow adaptation for batch alignments	42
4.3 Multiple alignment workflow	46
5.1 Length of conserved sequence per expression cluster	62
5.2 Top 22 non-random distributions of TRANSFAC motifs for non-exonic sequence	66
5.3 Top 11 non-random distributions of TRANSFAC motifs for exonic sequence	66
5.4 SRF induced genes from microarray experiment	71
5.5 Conserved putative binding sites	74
5.6 Comparison of in-silico predictions to ChIP experiment of Ren et al.	75
5.7 Comparison of SRF target gene sets	80

Abbreviations

Abbreviations in alphabetical order

A, A	adenine
bp	base pair(s)
°C	degree celsius
C, C	cytosine
cDNA	complementary DNA; DNA synthesized from mRNA by RT
CDS	coding sequence
ChIP	chromatin immunoprecipitation
CNB	conserved noncoding block; suboptimal local alignment
cRNA	complementary RNA
DNA	deoxyribonucleic acid
FDR	false discovery rate
G, G	guanine
Kb	kilobase(s); 1,000 nt
LPS	lipopolysaccharide
Mb	megabase(s); 1,000,000 nt
mRNA	messenger RNA
nt	nucleotide(s)
PAM	point accepted mutation
PCR	polymerase chain reaction
POA	partial order alignment
POG	partial order graph
PSSM	position specific score matrix
PWM	position weight matrix
RNA	ribonucleic acid
RT	reverse transcription
RTase	reverse transcriptase; an enzyme
RT-PCR	reverse transcription-polymerase chain reaction
SNP	single nucleotide polymorphism
SQL	structured query language
SRF	serum response factor
T, T	thymine
TF	transcription factor
TFBS	transcription factor binding site
tRNA	transfer RNA

U, U uracil

UTR untranslated region; part of mRNA transcripts

For a compilation of IUPAC symbols for nucleotide nomenclature see Appendix F.

Appendix

A Kurzzusammenfassung

Diese Promotionsarbeit beschäftigt sich mit der Steuerung der Transkription von Genen in Vertebraten im Allgemeinen und Säugern im Speziellen. Der Vorgang der Transkription ist das Abschreiben von Genen in eine RNA Kopie und stellt den ersten Schritt auf dem Weg zum Genprodukt dar. Unmittelbar um den Transkriptionsstart liegen Sequenzelemente, die hauptsächlich für die Effizienz des Transkriptionsvorganges relevant sind. Diese Sequenzelemente werden als Promotoren bezeichnet. Die Ausdehnung von Genen und Bereichen zwischen den Genen ist in Säugetieren beträchtlich groß (bis zu 1 Mb). Transkriptionsstartpunkte und somit Promotoren lassen sich experimentell nur schwer erfassen.

Mein Ansatz nutzt die vergleichende Analyse orthologer Sequenzbereiche aus verschiedenen Spezies. Die Grundidee ist das Aufspüren von konservierten regulatorischen Sequenzelementen und Promotorbereichen. Diese Elemente sind deshalb konserviert weil ein Ausfall oder Fehlen zur Fehlsteuerung des Genprodukts führen würde, das ähnliche Aufgaben in den entsprechenden Spezies verrichtet. Regulatorische Sequenzelemente stehen somit unter selektivem Druck. Mithilfe verschiedener etablierter und neu entwickelter Algorithmen wurde eine umfassende Sammlung solcher konservierter regulatorischer Elemente berechnet. Diese Daten wurden dann gegen bekannte Transkriptionsfaktorbindemuster abgeglichen. Die resultierenden Daten wurden rechnerisch mit den Resultaten anderer biologischer Experimente verknüpft. Aufbauend auf einer statistischen Analyse der Verteilung der relevanten Muster, lässt dies Schlussfolgerungen zur Funktionalität dieser Muster zu.

Die Arbeit behandelt die folgenden Bereiche:

- 1. CORG Datenbank** Das CORG (Comparative Regulatory Genomics) Projekt vereint eine Vielzahl an Methoden und Daten zur Vorhersage von Promotorbereichen. Zunächst werden Gruppen homologer Gene für die vergleichende Sequenzanalyse definiert. Upstreambereiche der Gene, die den eigentlichen Promotorbereich mit hoher Wahrscheinlichkeit enthalten, werden auf Sequenzebene miteinander verglichen. Hierzu wird der Waterman-Eggert Algorithmus zum Auffinden lokaler Sequenzähnlichkeiten herangezogen. Um eine Signifikanz der beobachteten Alignmentpunktzahl zu bestimmen wird die Verteilung aus zufälligen Alignments als Poissonverteilung approximiert. Nicht-translatierte Exons werden durch den Vergleich mit assemblierten EST Sequenzen detektiert. Transkriptionsfaktorbindestellen werden innerhalb konservierter Sequenzabschnitte durch

Konsensmuster oder Gewichtsmatrizen vorhergesagt. Alle Daten sind in einer relationalen Datenbank abgelegt, die über eine graphische Benutzeroberfläche und PERL-Schnittstelle zugänglich ist.

2. Vorhersage von Zellzyklusregulatoren. Periodisch exprimierte Gene wurden in 5 Gruppen eingeteilt, die den Zellzyklusphasen M/G1, G1/S, S, G2 und G2/M entsprechen. Für jede dieser Gruppen wurde ein Profil der konservierten Bindungsstellen in den dazugehörigen Upstreambereichen erstellt. Die Verteilung der Bindungsstellen über alle Gengruppen wurde in Relation zu einem Nullmodell gesetzt. Das Nullmodell beruht auf der Annahme, dass zufällige Bindungsstellen proportional zur Größe des Sequenzsuchraums auftreten. Die Abweichung von beobachteter Verteilung von Bindungsstellen zu erwarteter Verteilung wurde mit einem exakten und einem approximativen Test bewertet.

3. Detailstudie SRF-induzierter Gene. Der Serum Response Factor (SRF) ist an einer Vielzahl biologischer Prozesse beteiligt: u.a. Immunantwort, Herzentwicklung, embryonale Frühentwicklung und Neurogenese. Im Rahmen dieser Arbeit wurden die Promotoren von zwei Gengruppen studiert, welche durch SRF induziert wurden.

Die erste Gruppe umfasst Gene, welche durch SRF im *Srf* -/- embryonalen Stammzellen der Maus induziert werden. Die zweite Gruppe beinhaltet Gene die durch Stimulation humaner dendritischer Zellen mit LPS als Teil der Immunantwort induziert werden. Die Rolle von SRF und die Qualität der CORG Promotoranalyse wurden zunächst eingehend in embryonale Stammzellen der Maus studiert. Die signifikante Anreicherung von konservierten SRF Bindungsstellen und deren experimentelle Validierung mittels Chromatin-Immunopräzipitation lassen auf eine hohe Güte der CORG Promotoranalyse schließen.

Das CORG Projekt wurde im Rahmen dieser Promotionsarbeit etabliert und dessen Nutzen anhand von biologischen Fragestellungen klar belegt. Das CORG Rahmenwerk ist offen und flexible gestaltet. Neue Datenströme aus einer Vielzahl an Experimenten werden so noch den Weg in die CORG Architektur finden.

B Erklärung zur Urheberschaft

Hiermit erkläre ich, dass ich diese Arbeit selbstständig verfasst und keine anderen als die angegebenen Quellen und Hilfsmittel verwendet habe.

Christoph Dieterich

Berlin, im August 2004

B Erklärung zur Urheberschaft

C List of related publications

Michael M., Dieterich C., Stoye J. (2004) *Suboptimal Local Alignments across Multiple Scoring Schemes*. WABI 2004 - 4th Workshop on Algorithms in Bioinformatics, in press.

Dieterich C., Rahmann S., Vingron M. (2004) *Functional Inference from Non-random Distributions of conserved predicted Transcription Factor Binding Sites*. Bioinformatics. Suppl 1:I109-I115.

Samsonova A., Dieterich C., Vingron M., Brazma A. (2004) *Search for Regulatory Motifs in the Drosophila melanogaster genome*. BGRS 2004 - 4th International Conference on Bioinformatics of Genome Regulation and Structure.

Dieterich C., Herwig R., Vingron M. (2003) *Exploring potential Target Genes of Signaling Pathways by predicting conserved Transcription Factor Binding Sites*. Bioinformatics. Suppl 2:II50-II56.

Dieterich C., Wang H., Rateitschak K., Luz H., Vingron M. (2003) *CORG: A Database for Comparative Regulatory Genomics*. Nucleic Acids Research 31(1):55-7.

Dieterich C., Cusack B., Wang H., Rateitschak K., Krause A., Vingron M. (2002) *Annotating regulatory DNA based on Man-mouse genomic comparison*. Bioinformatics. 18 Suppl2:S84-90.

D Curriculum vitae

Dipl.-Biol. Christoph Dieterich
Leichhardtstraße 59
D-14195 Berlin, Germany
Tel.: ++49 – 30 – 83 33 85 30
E-mail: Christoph.Dieterich@molgen.mpg.de

Date of birth: January 7, 1975
Place of birth: Peine, Germany
Citizenship: German
Marital status: Married, two children

Degrees

MRes in Bioinformatics, University of York, UK. Degree with distinction

- Research experience in EST analysis, exploring the protein fold space and JAVA application development.

MSc in Technical Biology, University of Stuttgart, Germany. Grade: 1.0

- Diploma thesis: “In vitro infection models for *Candida albicans*”, Fraunhofer Institute for Interfacial Engineering and Biotechnology, Grade: 1.0
- Research experience in protein engineering, cell biology and prokaryotic genetics.

Education

2001 - present PhD student in the department of Computational Molecular Biology, MPI for Molecular Genetics, Berlin

2000 - 2001 Bioinformatics student at the University of York, UK

1994 - 2000 Biology student at the University of Stuttgart, Germany

1985 - 1994 Staufer-Gymnasium in Waiblingen, Germany (Abitur: 1.3)

Prizes and Awards

2000 - 2001 Scholarship from the Serono Pharmaceutical Research Institute, Geneva, Switzerland.

2000 Hugo Geiger prize for junior scientists (founded by the Bavarian government).

1996 - 2000 Scholarship from the Hanns-Seidel-Stiftung, Munich, Germany.

E Availability

E.1 The modified SIM implementation

The original SIM program is a linear-space implementation of the Waterman-Eggert algorithm by Huang and Miller (1991). We added several features to the program: significance assessment of alignment score (p-value computation), handling of multiple FASTA files and score matrix files.

Our program SIMSTAT is available from <http://corg.molgen.mpg.de/software>

E.2 Other software

All software related to the build up, maintenance, visualization and querying of CORG is available on request. Please contact christoph.dieterich@molgen.mpg.de.

E.3 CORG Database

MySQL dumps as well as flatfile dumps of the CORG database are made available via <http://corg.molgen.mpg.de/downloads>. Alternatively, a DAS server exists that provides the same data. Visit <http://tomcat.molgen.mpg.de:8080/das> for an overview of the available resources.

F IUPAC nucleotide ambiguity codes

Symbol	Meaning	Nucleic Acid
A	A	Adenine
C	C	Cytosine
G	G	Guanine
T	T	Thymine
U	U	Uracil
M	A or C	
R	A or G	
W	A or T	
S	C or G	
Y	C or T	
K	G or T	
V	A or C or G	
H	A or C or T	
D	A or G or T	
B	C or G or T	
X	G or A or T or C	
N	G or A or T or C	

Reference: IUPAC-IUB SYMBOLS FOR NUCLEOTIDE NOMENCLATURE: Cornish-Bowden (1985) Nucl. Acids Res. 13: 3021-3030.