

データ解析融合研究開発チーム成果報告

データ解析融合研究開発チーム

宮野 悟

次世代計算科学研究開発プログラム
データ解析融合研究開発チーム チームリーダー



発表者紹介

- 1977年3月 九州大学理学部数学科卒業
1979年3月 九州大学大学院理学研究科修士課程数学専攻修了
1979年6月 九州大学理学部助手
1985年4月 Alexander von Humboldt 財団研究員
1987年4月 Universität GH Paderborn 助手
1987年12月 九州大学理学部助教授
1993年3月 九州大学理学部教授
1996年4月 東京大学医科学研究所教授

研究分野

計算システム生物学、バイオインフォマティクス、メディカルインフォマティクス

データ解析融合研究開発チーム

宮野 悟

次世代計算科学研究開発プログラム
データ解析融合研究開発チーム チームリーダー

1. 目的

計測技術の大規模化・精緻化・簡便化により、遺伝子から環境因子にわたる生命システムに関するデータが、超高次元化・超ヘテロ化・超膨大化した。しかも、不観測性・欠損の問題も同時に有している。こうした中、データ解析はデータの多様化と増大化に急速に引き離され、シミュレーションは生命体個別の現実データを反映できず予測能力に限界がある。方法論にパラダイムシフトが必要となった。

そこで本研究チームは、ペタスケールの計算を前提にして、超高次元大規模ヘテロデータ解析技術と生命体シミュレーションを融合し、生命体システムに対する予測と発見の基盤情報技術を構築することを目的として研究開発を行っている。4人のPIが、図1の文脈で、次の3つの技術開発を目標に研究を行ってきた。

- ① ゲノムワイド関連解析により疾患や薬物反応性などの表現型に関連する遺伝子の解明と、個人の表現型をゲノム情報と環境情報により予測する技術
 - 理化学研究所ゲノム医科学研究センター・角田達彦(2011.4～)；鎌谷直之(2006.10～2011.3)
- ② 大規模な生体分子のネットワークを推定する技術を開発し、これを「地図」として薬物・疾患に関与する遺伝子群を探索する技術
 - 東大医科学研究所・宮野悟




図 1

- 東工大・秋山泰
- ③ データ同化技術の活用による一般のモデルから個のモデルを創出する技術
 - 統計数理研究所・樋口知之

2. 現時点での成果

2.1 「肺がんと薬」を研究の共通軸とする

本チームの研究開発は2006年に開始したが、2008年に実施された研究の進捗状況についての中間評価において、チームとして共通の研究軸をもつことによりチーム内での相乗効果を発揮させることが指示された。そこで、本チームのメンバーが実験データの取得も含め対応可能なものとして「肺がんと薬」を共通のテーマとした。そして、「肺がんと薬」をシステムを理解するための課題として、図2のように技術開発の方向を明確化した。

2.2 チームの構成と役割・開発ソフトウェア

図3のチームの構成と役割により、おもに5つに分類されるソフトウェア SiGN、MEGADOCK、ParaHaplotype、LiSDAS、SBiPを開発しており、京コンピュータ上での現時点での許された最大高並




図 2

列化(12280ノード)を一部達成している。

SiGNは、ヒト全遺伝子規模の遺伝子ネットワークを推定・探索するソフトウェアで、ベイジアンネットワーク、状態空間モデル、L1正則化法を駆使したネットワーク推定法に基づいたアプリケーション群がパッケージに含まれている。トランスクリプトームのネットワークを推定することに用いることができるが、ソフトウェアとしては生命科学に限らず、汎用的なものである。MEGDOCKは、1000×1000規模のタンパク質相互作用を網羅的に推定することでタンパク質ネットワークを構築できるソフトウェアである。網羅的なタンパク質間相互作用予測システムを京コンピュータの上で効率的に動作する並列ソフトウェアパッケージとしてまとめ、前処理・後処理のツール群も京コンピュータ周辺環境で動作するよう移植を行っている。MEGDOCKで予測されたタンパク質相互作用情報をトランスクリプトームネットワークと合わせてシステムを理解することを目指している。これらのソフトウェアを使ったデータ解析により、肺がんなどの分子ネットワーク・薬剤応答ネットワークを解析し、その分子病態を描出することを狙っている。他の疾患や薬にも応用可能である。

ParaHaplotypeは、肺がんに限ったものではなく、患者群と対照群の全ゲノム上のSNPを用いハプロタイプ単位のゲノムワイド関連解析を行い、疾患関連遺伝子を網羅的に探索するためのソフトウェアである。ファーストランナーとして京コンピュータ上で並列度を上げている。京コンピュータ上で実行させて、実際に肺がんや、その治療薬などに關係する形質を含め、新たな疾患関連遺伝子、形質関連遺伝子を発見する成果を目指している。これに関連して、拡張RAT法による2SNP組合せの全ゲノム関連解析ソフトウェア(ExRAT)を開発している。これは、病気へのリスクを上げる原因となるような複数の遺伝子による相乗効果を大規模体系的網羅的に見つけ出すソフトウェアであり、京コンピュータのアキテクチャに合わせ並列度を上げ、京コンピュータ上で実データを用いて実行させて、未知の複数要因による新たな疾患発症機序の発見と、未だ解決していない遺伝力の問題を解く成果を狙っている。また、次世代シークエンサーデータ解析プログラム(NGSanalyzer)は、がんを細胞変異のゲノム学と遺伝統計学により解明するために、次世代シークエンサーからの人間のがん細胞と正常細胞の全ゲノムの膨大なデータを網羅的・正確・高速に解析するためのソフトウェアである。現在、



図 3

パイプラインの並列度を上げ、京コンピュータ上で実行させて、実際のがんのメカニズムと日本人のゲノムの多様性の解明を目指している。こうした解析から見つかる遺伝子を、SiGNやMEGDOCKで推定したネットワーク(地図)にマップし、関連解析の結果を分子ネットワークで理解することを狙っている。

データ同化技術は、個別データをモデルに同化させ、個別化モデルを作り、個に対するシミュレーションと予測をするものである。LiSDASは、階層性を考慮した粒子フィルタアルゴリズムなどを京コンピュータ上で超高並列化したソフトウェアである。オミックス計測技術から生成されるデータを利用して、生体内分子相互作用ネットワークのシミュレーションモデルを構築することに応用することを目指している。

開発したソフトウェアを連携して使うことができるSBiP(Systems Biology integrative Pipeline)というデータ解析プラットフォームを開発している。SBiPは京コンピュータで走らせるソフトウェアではなく、ユーザのコンピュータにインストールし、高機能GUIにより、SBiPから京コンピュータの上で走るソフトウェアをつないで解析パイプラインを作成できるものである。

また、おもにSiGNとLiSDASの開発を進めるために肺がんと抗がん剤ゲフィチニブに関するmRNAなどの時系列データを若干取得し、活用している。

3. プロジェクト終了時の達成目標

ネットワーク解析による薬のターゲット探索やがんなどの病態を理解する情報技術、並びにゲノム情報に基づいた個人差を考慮した医療のための基盤情報技術を創出する。

データ解析融合チームの背景・目的

ISLiM

「一般」のデータ
トランスクリプトーム、プロテオームデータをはじめとする生命システムの観測データ

「個」のデータ
百～数万人の個人SNP及びゲノム配列。個人の疾患や薬物反応、質的・量的形質データ

「一般」の分子ネットワークモデル=「地図」
遺伝子ネットワーク
タンパク質ネットワーク

「個」のモデル
Aさん
Bさん
甲薬
乙薬

①表現型(疾患や薬物反応が)、に影響する遺伝子の解明と、個人の表現型をゲノム情報を通じて遺伝子群を予測する技術。
②大量複数の生体分子のネットワークを推定する技術を開発し、これを「地図」として薬物、疾患、遺伝子群を予測する技術。

③「個」のデータを「一般」のモードルに合体的に「コラボ」させる生命システムのためのデータ同化技術の開発。
2

概要・アプローチ・開発ソフトウェア

ISLiM

遺伝子ネットワーク
ヒト全遺伝子規模にわたる
遺伝子ネットワークの
構造・解析
解析

肺がんの分子ネットワーク
肺がんの分子ネットワークを解析し
肺がんの分子構造を描出

タンパク質ネットワーク
タンパク質ネットワーク
作用推定でネットワークを網羅的に解析

大規模SNP関連解析
1000x1000タンパク質相互作用
効果・副作用と遺伝子との関連付け

ゲノムバリエーション
肺がんの特性、抗がん剤の
効果・副作用と遺伝子との関連付け

シミュレーション
個別データをモデルに同化させ、個別化モデルを作る

SBiP Systems Biology Integrative Pipeline

「肺がんと薬」データの取得

データ解析融合研究開発チーム チーム成果統括報告

ISLiM

理化学研究所
次世代計算科学研究開発プログラム
データ解析研究開発チーム チームリーダー
宮野 悟

東京大学(宮野 悟)
大規模遺伝子ネットワーク推定とその応用
東京大学
統計数理研究所
生命体統合シミュレーションのためのデータ開発
化技術の開発

東京工業大学(秋山 泰)
大規模タンパク質ネットワーク推定とその
応用
東京工業大学
統計数理研究所

理化学研究所(角田達彦)
大規模ゲノム多型データと表現型
データを同時に扱う新規アルゴリズムの開発と、妥当性、有用性の検討
ISLiM成果報告会2011

「肺がんと薬」のシステムを理解するための課題

ISLiM

データ解析融合研究開発チームのソフトウェア




がんの分子病態
がんの分子病態と質的形質・環境因子との関連を捉える





薬剤に応答し、耐性を獲得していくがんの分子病態などを動的・静的システムとして捉える




個人個人のがんの属性・多様性をシステムとして捉える
個人に対応したシミュレーションヒューリスティクス

創薬ターゲット探索や個人・差を考慮した診断、治療、予防法などの医療開発に貢献

3







ISLiM

現時点での達成状況と課題

【進捗状況】

- ・ソフトウェアに関しては、独創的な手法が開発され、優先順位をつけて京での現高並列化がほぼ順調に進行している。現時点でも可能な最大規模に達している。

【課題】

- ・4PIの成果をつなぎで初めて得られるようないシナジー効果がある成果がまだ出せない。

ISLiM

「肺がんと薬」に関するデータの取得

細胞
■正常ヒト小気道上皮細胞
SAEC52, SAEC97
■肺腺がん細胞株PC9
■Gefitinib耐性株PC9GRM2、他

-24 -2 0 0.5 1 2 3 24 27 30 33 36 39 43 48 (hours)

Sampling

4つの実験条件

コントロール
EGFのみ追加
Gefitinibを吸収しておいてEGFで刺激
Gefitinibを投与

mRNA
タンパク質

17

ISLiM

プロジェクト終了時の達成目標

- ・50万SNPを自在に解析可能にする大規模SNP解析ソフトウェア
- ・ヒトの全遺伝子・転写産物を対象したネットワーク解析を可能にする大規模遺伝子ネットワーク推定ソフトウェア
- ・1000 × 1000の超大規模計算を可能にする網羅的タンパク質間相互作用推定ソフトウェア。
- ・「個」のデータを「一般」のモデルに合理的にフィットさせる生命システムのためのデータ同化を柱としたプログラム群。
- ・以上を、融合し、統合的に利用活用するためのソフトウェア

→

- ・ネットワーク解析による薬のターゲット探索やがんなど
の病態を理解する情報技術
- ・ゲノム情報に基づいた個人差を考慮した医療のため
の基盤情報技術

19

全ゲノム解析の超並列化による 疾患研究の加速

角田 達彦

理化学研究所 ゲノム医科学研究センター
統計解析・技術開発グループ グループディレクター



発表者紹介

- 1995年3月 東京大学大学院 工学系研究科 情報工学専攻博士課程修了
1995年4月 京都大学大学院 工学研究科 助手
1997年4月 東京大学医科学研究所 ヒトゲノム解析センター リサーチアソシエイト
1998年4月 東京大学医科学研究所 ヒトゲノム解析センター 助手
2000年4月 理化学研究所 遺伝子多型研究センター チームリーダー
2008年4月 理化学研究所 ゲノム医科学研究センター チームリーダー
2011年4月 理化学研究所 ゲノム医科学研究センター グループディレクター

医学博士・工学博士

研究分野

ゲノム医学、遺伝統計学、メディカルインフォマティクス

 ISLiM

背景・目的

- 背景: 全くの未知のものも含め、疾患の原因を探査するには、全ゲノム上で患者群と对照群との間でゲノムDNA配列を比較する、ゲノムワイド関連解析 (GWAS) が極めて有効であり、われわれ理化学研究所ゲノム医科学研究センターでは、2002年に世界に先駆け初めてこのGWASを実現してから、世界を牽引してきた。この方法論をさらに劇的に推進するためには、単点の解析だけでなく、近傍の、あるいは遠距離にある複数点の解析を行ったり(それぞれParaHaploとExRAT)、対象とするマークターを、これまでの固定されたセットから拡張し、より全ゲノム配列への探索を行ったり(NGS analyzer)するなどの新たな方法論を導入する必要がある。これらには、スルバーコンピューティングを駆使することが必要不可欠になる。
- 目的:
 - ParaHaplo: GWASの方法論を拡張し、単点ではなく連続する複数点に対して超並列に行うことによって、飛躍的な検出力の向上と高速性能を狙う。
 - ExRAT: 複数の遺伝子の相互作用により発症する可能性を、全ゲノム上で網羅的に超並列に探索する。
 - NGS analyzer: 次世代シークエンサーの発発的データを超並列に処理し、ゲノム多様性を高精度かつ包括的に解析する。

ISLiM成果報告会2011 2

 ISLiM

現在までの研究開発成果

- 現時点の開発ソフトウェア ParaHaplo について
 - ParaHaplo ver. 3.0, phase II-2, 96%
 - 富士通コンパイラ (RICC, FX1, 「京」) の全てに対応済、実行成功
 - PCクラスタで8,000ノードの並列性能を実証。
 - 「京」でも並列性能が出来ることを確認。
 - 「京」ではコア並列(ハイブリッド並列)も実装している。
 - 現在は、一層の高速化を目指しSIMD化を行っている。
 - ソースコード公開済。
- 論文出版: Misawa K, Kamatani N (2011) ParaHaplo 3.0: a program package for imputation and haplotype-based whole-genome association study using parallel computing. Source Code Biol Med.

ISLiM成果報告会2011 4

 ISLiM

全ゲノム解析の超並列化による疾患研究の加速

理化学研究所 ゲノム医科学研究センター グループディレクター 角田 達彦

ISLiM成果報告会2011 1

 ISLiM

概要・アプローチ

- 研究開発コードの概要
 - ParaHaplo: 人のゲノム全体にわたる遺伝的な相違点を、近傍にある複数点を同時にみたハイブリッドという単位で、患者群と対照群とで比較することにより、疾患の遺伝的原因を探るために用いられる統計検定計算
 - ExRAT: 遺伝子間相互作用が発症リスクを変化させる疾患関連遺伝子の組合せを全ゲノムで探索する。2SNP間の全組合せを超並列に行う方法と、SNP間の連鎖不平衡(相関)も考慮した、より精密な方法の2種類を実装。前者で全組合せをスクリーニングし、後者で経験的p値を求める手順を想定している。
 - NGS analyzer: 次世代シークエンサーの出力データを高速に解析し、個人間の遺伝的差異やがんゲノムの突然変異を高い正確さで同定する。
 - アプローチ
 - ParaHaplo: Haplotype頻度を用いたType I errorの確率計算を、ハイブリッド並列で実装したマルコフ連鎖モンテカルロ法で行う。
 - ExRAT: RAT(Rapid Association Test)を、データ分割法で実装したインボータンスサンプリング法で行う。
 - NGS analyzer: ヒト標準ゲノム配列に対するマッピングと確率計算に基づいた多様性検出を、領域分割で実装した直接法による密度行列の対角化により行う。

ISLiM成果報告会2011 3

<p>ISLiM</p> <h3>現在までの研究開発成果</h3> <ul style="list-style-type: none"> 現時点の開発ソフトウェア ParaHaploについて(続き) <ul style="list-style-type: none"> ParaHaploを実際のデータに応用した例。 点線より上が従来の方法で遺伝子頻度の差が検出できた場所。 実線より上がParaHaploで遺伝子頻度の差が検出できた場所。 <p style="text-align: center;"></p> <p style="text-align: center;">Manhattan Plot of Rapid Association Test (RAT)</p> <p style="text-align: right;">ISLiM成果報告会2011</p>	<p>ISLiM</p> <h3>現在までの研究開発成果</h3> <ul style="list-style-type: none"> 現時点の開発ソフトウェア ExRATについて <ul style="list-style-type: none"> ExRAT ver. 1.0β-1382, phase II-2, 100% 富士通コンパイラ(RICC, FX1, 「京」の全て)に対応済、実行成功、buildも可能。 PCクラスターで8,192ノードの並列性能を実証。 データ:患者708人、一般集団3397人、8314SNP、14100回permutationで評価。 ハイブリッド並列化対応: Preprocess処理とpermutation処理にOpenMPでのスレッショード化の実装。 Preprocess処理の見直しによるさらなる高速化: 分割表探索処理での計算処理の見直しにより、約40%程度高速化(計算処理を探索中に積み上げていけるように処理を変更し、全体の計算量の削減に成功した)。 MPIプロセスの増加によるメモリ使用量増加への対応: 非同期通信信用のためのバッファ確保が原因だったため、通信処理を見直し、処理完了待ちのバッファの大きさを最小とすることによって対処した。 テスト運用の結果から問題点の洗い出しおよび改善方法の検討を行ってきた。 <p style="text-align: right;">ISLiM成果報告会2011</p>
<p>ISLiM</p> <h3>現在までの研究開発成果</h3> <ul style="list-style-type: none"> 現時点の開発ソフトウェア ExRATについて(続き) <ul style="list-style-type: none"> スレッド数を増やしたときの処理効率の向上: スレッド間での同期待ちを出来るだけ少なく、処理効率向上を図る。 データサーバとの通信処理の改善: データサーバのレスポンスを改善するとともに、通信方法も見直し、全体の効率向上を進める。 MHサンプリングの処理で、スレッドを十分に活用できないので、これを改善する方法を検討する。 複数のSNPの組合せについての計算を、1ジョブで処理できるように改良する。 <p style="text-align: right;">ISLiM成果報告会2011</p>	<p>ISLiM</p> <h3>現在までの研究開発成果</h3> <ul style="list-style-type: none"> 現時点の開発ソフトウェア NGS analyzerについて <ul style="list-style-type: none"> NGS analyzer ver. 1.0, phase II-1, 80% PCクラスター上で20000並列を達成。 全ゲノムシークエンスデータの解析 <ul style="list-style-type: none"> ヒトの全ゲノムシークエンス解析からの一塩基多型(SNP), 挿入・欠失(indel), リアレンジメントを高い精度で検出 がん細胞における突然変異を高い精度で検出(東京大学医学研究所ヒトゲノム解析センターのPCクラスターにて実行) 変異や多型のタイプごとに、実験的検証を行うことで、パラメーターのチューニングを行った。 初の日本人の全ゲノムシークエンス(<i>Nature Genetics</i> 2010)、肝臓がんの全ゲノムシークエンス(<i>Nature Genetics</i> 2010)を解析 Fujimoto et al. <i>Nature Genetics</i>, 42, 931-936 (2010). The International Cancer Genome Consortium. <i>Nature</i>, 464, 993-998 (2010). <p style="text-align: right;">ISLiM成果報告会2011</p>

ISLiM

プロジェクト終了時の達成目標

- 達成目標:
 - ParaHaplo: 全ゲノムの個人ごとの遺伝情報の違いの中から、疾患に関連する遺伝情報を網羅的に精度よく探し出すことを行うプログラムを開発し、「京」の上で運用できるように実装すること。
 - 第一走者 ParaHaplo で、ハプロタイプゲノムワイド関連解析を、数千人の疾患群とコントロール群とのハプロタイプ頻度の比較を行い、新たな疾患関連遺伝子の探索を行うことを目指す。8万ノードを使い、計算時間は1つの疾患あたり1時間～数時間程を予定している。
 - ExRAT: 遺伝子どうしが相互作用を起こして疾患への発症リスクを上昇する現象とそれらの遺伝子を新たに疾患関連遺伝子として発見するためのプログラムを開発すること。そして実際に新たな疾患関連遺伝子の探索を行うことを目指す。
 - NGS analyzer: 全ゲノム配列(約30億塩基)の個人ごとの遺伝情報の違いを網羅的に精度よく検出するプログラムを開発すること。そしてがんの全突然変異を高速に検出し、創薬のターゲット分子を探索することに資することを目指す。

ISLiM成果報告会2011 10

現在までの研究開発成果

- 現時点の開発ソフトウェア **NGS analyzer** [について (続き)]
 - 初の日本人の全ゲノムシーケンス (*Nature Genetics* 2010) の解析例:
 - ヒトの遺伝的多様性の例として1番染色体上のSNPの密度の計算結果。
 - ・バージナルゲノム上に存在するSNPの頻度スペクトラムについての新たな知見。

ヒトの遺伝的多様性(1番染色体上のSNPの密度)

SNPの頻度スペクトラム

Fujimoto et al. *Nature Genetics*, **42**, 931-936 (2010).

ISLiM成果報告会2011 9

大規模遺伝子ネットワーク推定ソフトウェア SiGN とデータ解析融合プラットフォーム Systems Biology integrative Pipeline (SBiP)

宮野 悟

次世代計算科学研究開発プログラム
データ解析融合研究開発チーム チームリーダー



発表者紹介

- 1977年 3月 九州大学理学部数学科卒業
- 1979年 3月 九州大学大学院理学研究科修士課程数学専攻修了
- 1979年 6月 九州大学理学部助手
- 1985年 4月 Alexander von Humboldt 財団研究員
- 1987年 4月 Universität GH Paderborn 助手
- 1987年 12月 九州大学理学部助教授
- 1993年 3月 九州大学理学部教授
- 1996年 4月 東京大学医科学研究所教授

研究分野

計算システム生物学、バイオインフォマティクス、メディカルインフォマティクス

 大規模遺伝子ネットワーク推定ソフトウェアSiGN
の開発目的

肺がんなどの分子ネットワーク・薬剤応答ネットワークを解析し、その分子病態を描出するために、DNAチップ等で計測された遺伝子発現データから遺伝子間の発現の依存関係を表す「遺伝子ネットワーク」を推定・予測するソフトウェアを開発すること。



 遺伝子発現プロファイルデータからの
遺伝子ネットワークの抽出法


◇◆地図の作り方◆◇

- システムを捉えるための観測データ
 - 刺激後の時系列データ
 - 遺伝子KD後のデータ、など
- 因果・制御関係の数理モデル
 1. BN: Bayesianネットワーク+非線形回帰
 2. SSM: 状態空間モデル+次元圧縮
 3. "Modulator"と構造方程式を用いたグラフィカルモデル

ISLiM成果報告会2011

 大規模遺伝子ネットワーク推定ソフトウェア
SiGNとデータ解析融合プラットフォーム
(SBiP)


データ解析融合研究開発チーム
東京大学医学研究所
宮野 悟



ISLiM成果報告会2011

 SiGNの目標

最適な数十遺伝子規模のネットワークからゲノムワイド(2万遺伝子)ネットワークまで、動的・静的ネットワークの推定が可能となること。



ISLiM成果報告会2011



大規模遺伝子ネットワーク推定技術の

現在までの主な成果


- SiGN-BN (ベイジアンネットワーク)
 - 大規模全ゲノム遺伝子ネットワーク推定アルゴリズム(SiGN-BN-NINN)
 - 中規模高効率並列ブートストラップアルゴリズム(SiGN-BN-HC-Bootstrap)
 - 京での並列化が大きく進行中
 - 小規模並列版錯的・動的全体最適化アルゴリズム(SiGN-Para-OS)
 - 効率のよい高並列化は難しい(256ノードぐらいの長い計算が効率的)
- SiGN-SSM (状態空間モデル)
 - 遺伝子ネットワーク推定アルゴリズム
 - モジュールネットワーク推定アルゴリズム
 - 遺伝子発現予測アルゴリズム
 - RICCで8192コア。京での並列化を準備中
- SiGN-L1 (L1正則化ネットワーク)
 - NetworkProfilerによる(京での並列化を準備中)
 - NetComparatorによる複数ネットワーク同時推定・比較アルゴリズム

6

ISLiM成果報告会2011



Nonparametric Regression

Here $m_k(\cdot)$ is a smooth function from R to R.

ISLiM成果報告会2011




SiGN+スノーピコンで、たとえば、次のようなことが
可能になってきた。

- 抗がん剤に応答して動的に変化する大規
模な遺伝子ネットワークを描出すること
- 数百のがんサンプルの遺伝子発現プロファ
イルデータから個々のがんの個性・多様性
を分子ネットワークとして抽出すること
- これらを地図として用いて、新たな分子標
的探索の可能性ができた

ISLiM成果報告会2011



Bayesian Network



ISLiM成果報告会2011

$$f(x_{i1}, \dots, x_{ip} | \boldsymbol{\theta}_G) = \prod_{j=1}^p f_j(x_{ij} | \mathbf{p}_{ij}, \boldsymbol{\theta}_j)$$

“難しいのはみんなの仕事ぶりデータからネットワーク構造を推定すること”

Nonlinear Bayesian network model

$$f_j(x_{ij}, \dots, x_{ip}; \boldsymbol{\theta}_j) = \prod_{l=1}^p f_l(x_{il} | \mathbf{p}_{il}; \boldsymbol{\theta}_j),$$

$$f_l(x_{il} | \mathbf{p}_{il}; \boldsymbol{\theta}_j) = \frac{1}{\sqrt{2\pi\sigma_j^2}} \exp\left\{-\frac{(x_{il} - \mu_{ij})^2}{2\sigma_j^2}\right\}$$

ただしやのパラメータ

$$\mu_{ij} = m_1(p_{il}^{(j)}) + \dots + m_{q_j}(p_{iq_j}^{(j)})$$

$$= \sum_{k=1}^{q_j} \sum_{m=1}^{M_{ik}} \gamma_{mk} b_{mk}^{(j)}(p_{ik}^{(j)})$$

ISLiM成果報告会2011

“数学的にはこんな感じになります”

Criterion for selecting good networks

BNRC Score

Bayesian Network and Nonparametric Regression Criterion


$$\begin{aligned} \text{BNRC}(G) &= -2 \log \pi_G \int \prod_{i=1}^n f(\mathbf{x}_i; \boldsymbol{\theta}_G) \pi(\boldsymbol{\theta}_G | \lambda) d\boldsymbol{\theta}_G \\ &= -2 \log \pi_G - r \log(2\pi n^{-1}) \\ &\quad + \log|J_\lambda(\hat{\boldsymbol{\theta}}_G)| - 2nl_\lambda(\hat{\boldsymbol{\theta}}_G | \mathbf{X}_n) \end{aligned}$$

この“BNRC score”が小さいネットワーク構造
とパラメータを探索する。“スパンがどこで必要になる”

ISLiM成果報告会2011



Bayesian Network + Nonparametric Regression Dynamic BN (時系列データに限定した方法)



遺伝子ネットワーク
Gene Knockdown/Knockout
Time-Course Measurement

1. Imoto, S., Goto, T., Miyano, S. Estimation of genetic networks and functional structures between genes by using Bayesian network and nonparametric regression. *Pacific Symposium on Biocomputing*, 7:175-186, 2002.
2. Imoto, S., Goto, T., Miyano, S. Bayesian network and nonparametric regression for nonlinear modeling of genetic network. *Bioinformatics and Comp. Biol.*, 1(2), 231-252



ISLiM成績報告会2011


メラノーマ細胞の遺伝子ネットワークとタキソール
具体的にどんなことが今の段階でできているのか-ダイナミックペイジアン+非線形回帰

- 細胞：メラノーマ細胞株 A-375
- 薬：タキソール(Paclitaxel、抗がん剤)
- Microarray: Illumina® HumanHT-12 v3
- データ：14 時点、3 回計測、計 84 アレイデータ
 - 0h, 15min, 30min, 45min, 1h, 1.5h, 2h, 3h, 4h, 6h, 8h, 12h, 18h, 24h
 - タキソール投与と非投与の 2 種類のデータ
- 目的：タキソールを投与したメラノーマ細胞の遺伝子ネットワークの動的変化を見ることで、新たなターゲット遺伝子を探索


ISLiM成績報告会2011

Cell Innovator, C. Print (U Auckland)との共同研究






肺がん細胞株PC9/PC9GRに対するGefitinib動的効果推定




20
19
18
17

ISLiM成果報告会2011
19



正常肺上皮細胞SAEC+EGF(+Gefitinib)投与下EGF応答パスウェイ解析



 SIGN-L1でできること


1サンプルから因果・制御のネットワークを抽出するのには無理

クラスタリング

2サンプルだとFold-Change Analysis


因数・制御のネットワーク

1サンプル



しかし、たくさんサンプルがあると…

 モジュレータ: 遺伝子AとBの条件付き従属性に影響を与える因子を導入



 L1正則化法による大規模遺伝子ネットワーク推定プログラム


- SIGN-L1はL1正則化法によるスパースな統計的グラフィカルモデル(グラフィカルガウシアンモデル、ベクトル自己回帰モデル、構造方程式モデル)を用いた遺伝子ネットワーク推定ツールウェア

ISLiM成果報告会2011 21

 データの層別化による相関構造の違い





$X_2 = -0.07 \times X_1 + \epsilon_2$
特微量が高いとき

$X_2 = -0.92 \times X_1 + \epsilon_2$
特微量が低いとき



データの層別化

がんの「特微量」を導入すれば、関係がでてくる
⇒サンプルそれぞれのネットワークを推定できる。



EMTに関する がん細胞株の遺伝子ネットワークの推定

Sanger Center 公開データ
762 個のがん細胞株マイクロアレイデータ
様々ながん種
13,508 transcripts=13,006 mRNA+502 miRNA

モジュレータ: EMTness (低: 上皮細胞, 高: 間葉細胞)
1,024 cores (12:3 TFLOPS) を
使って3ヶ月の計算

ISLiM成績報告会2011

スノーパコンが予測したEMT制御因子たちと 新規遺伝子KLF5の発見 スパコンによる大規模データ解析の有効性

Shinamura T, Iimoto S, Shimada Y, Hosono Y, Nida A, Nakasaki M, Yamaguchi R, Takahashi T, Miyano S. A novel network profiling analysis reveals system changes in epithelial-mesenchymal transition. PLoS ONE. (6):e23804, 2011.

a si KLF5#1
Mock TGF- β
b si NC si KLF5#1
Mock TGF- β
c si NC si KLF5#1
Mock TGF- β

モジュレータ: EMTness (低: 上皮細胞, 高: 間葉細胞)

50 個の上皮・間葉マーカー遺伝子の第一主成分

Signature-based hidden modulator extraction algorithm


- Selected 122 genes labeled "EMT UP", "EMT DN", "JECHLINGER EMT UP", and "JECHLINGER EMT DN" from Molecular Signatures Database v2.5 [16]; <http://www.broadinstitute.org/gsea/msigdb/index.jsp>
- Then, narrowed the set to 50 functionally coherent genes with $p < 10^{-5}$ by using the extraction of expression module (EM).
- Computed the first principal component of these 50 genes as hidden values of the EMT-related modulator

EMTで変化する大規模遺伝子ネットワークを1024コアで3ヶ月間かけて計算

➤ 13,508個の遺伝子から構成される遺伝子ネットワークを762個のネットワークがEMTの度合でその構造がどう変化するかが暴き出された。

上皮系がん細胞 E-cadherin ZEB1
間葉系がん細胞

ZEB1の遺伝子発現プロファイル
Epithelial Mesenchymal Epithelial Mesenchymal



500種類の解析するには どれだけ計算リソースが必要か？

1000コア (12TFLOPS)だと25年
K computerだと2週間

データ解析融合プラットフォーム

SBiP (Systems Biology integrative Pipeline)

- SiGN、LiSDASを解析パイプラインのコンポーネントとしてユーザーが簡単に利用できる高機能GUIを備えたソフトウェアプラットフォーム
- 京に用意されているジョブスケジューリングシステムと連携し、京にて各解析パイプラインの処理の一部を実行し、その結果を、SBiPの視覚化コンポーネント群を用いて保存できるよう目指している。
- ユーザはSBiPに用意されているさまざまな解析コンポーネントを組み合わせてカスタマイズした解析フローを実行可能。

ISLiM成果報告会2011 35



再発リスクに関する日本人肺癌患者の遺伝子ネットワークの比較

データ: 226症例の肺癌がん患者の遺伝子発現データ
(国立がん研究センター横田淳先生、河野隆志先生との共同研究)
目的: 再発リスクをモジュレーターとしたときの226症例各自の遺伝子ネットワークを推定し、再発リスクが高い患者と低い患者のシステムの違いを比較

世界水準との比較—SiGN

- 京に代表される超並列計算機を用いる遺伝子ネットワーク推定プログラム、細胞外基質算出、血管新生作用を有するSiGNを除いて世界に無い。
- よく知られているARACNE (Andrea Califano, Columbia Genome Center)とは、精度・解析規模・解析法の多様性の点からSiGNが優れている。

ISLiM成果報告会2011 35



網羅的タンパク質間相互作用 予測ソフトウェア MEGADOCK の開発と応用

秋山 泰

東京工業大学 大学院
情報理工学研究科計算工学専攻



発表者紹介

- 1990年3月 慶應義塾大学大学院理工学研究科電気工学専攻博士課程修了(工学博士)
1990年4月 通商産業省工業技術院電子技術総合研究所 研究官
1992年4月 京都大学 助教授(化学研究所)
1996年4月 技術研究組合新情報処理開発機構 研究室長(並列応用つくば研究室)
2000年4月 通商産業省工業技術院電子技術総合研究所 主任研究官(生命情報科学研究センター検討チーム長)
2001年4月 独立行政法人産業技術総合研究所 生命情報科学研究センター長
2007年4月 東京工業大学大学院情報理工学研究科計算工学専攻 教授

研究分野

バイオインフォマティクス、並列処理応用

ISLiM

タンパク質間相互作用ネットワークの推定とその応用に関する研究

- 目的
 - タンパク質ネットワーク予測のための超大規模計算システムを開発する。
 - 膨大なタンパク質候補の中からタンパク質間相互作用を予測し、創薬ターゲットとして提示。個人の遺伝子型から表現型を予測するバイオラインの一部となる。
- 2012年までの目標
 - システム生物学が対象とする網羅的超大規模計算(2000x2000級)を現実的な時間で計算可能にする

ISLiM

アプリケーションの概要

- 離散化(計算モデル化)の方法
 - 二つの構造間の結合性を三次元複素量込みで評価
- 計算方法
 - 形状相補性と静電相互作用スコアを一つの複素数で表し(IPSC)、二体間の量込み和をフーリエ空間上で行い逆FFTで評価直を得る。
 - 並列化の方法
 - ノード内の回転角度並列:
 - OpenMP
 - ノード間のデータ並列: MPI

ISLiM

網羅的タンパク質間相互作用予測ソフトウェア MEGADOCKの開発と応用

東京工業大学
大学院情報理工学研究科 計算工学専攻
秋山 崇

ISLiM

概要・アプローチ

- 研究開発コードの概要
 - タンパク質立体構造情報に基づき、表面形状相補性と静電相互作用を用いた単純化した評価モデルを新規に提案した。FFTを用いて計算量を大きく減じ、さらにOpenMPとMPIによるハイブリッド並列機能を実装することにより、大規模並列計算機上で効率的な並列計算を行う。
- MEGADOCKによるPPIネットワーク予測
 - 入力したタンパク質群の構造について、網羅的に剛体ドッキングを行い、複数の複合体構造を出力する。ポストドッキング解析により、**タンパク質間相互作用ネットワーク**を予測する。

相互作用予測				
網羅的ドッキング				
P1	P2	P3	P4	P5

剛体ドッキング

- Rigid Docking(Grid base & Scoring function)
 - タンパク質立体構造の形状相補性等に基づいて評価
 - タンパク質をボクセル空間で表現
 - 特定のスコアリングモデルに基づいてスコアを付与
 - それらの量み込み和で評価関数を表す

15度刻み
3600通りの探索

best score = 8

best score = 5

ISLiM成果報告会2011 Katchalski-Katzir E, et al. PNAS, 1992.

新規に提案したスコアリングモデル: rPSC

- real Pairwise Shape Complementarity (rPSC)
 - 形状相補性のスコアを実数のみで表現

MEGADOCK Score

$$\text{MEGADOCK Score} = \text{rPSC} + i \text{ Elec}$$

$\hat{g}_R(L, m, n) = \frac{\# \text{ of R atoms within } [3 \text{ Å}, R \text{ atom radius}]}{0.27} \text{ inside of the R solvent accessible surface layer of the L solvent excluding the surface layer of the L open space}$

$$\hat{g}_L(L, m, n) = \frac{\# \text{ of L atoms within } [3 \text{ Å}, R \text{ atom radius}]}{0.27} \text{ inside of the L solvent accessible surface layer of the L solvent excluding the surface layer of the L open space}$$

$$\hat{S}'(R, \theta, \phi) = R \sum_{l=1}^N \sum_{m=-l}^l \sum_{n=-l}^l \hat{g}_L(l, m, n) \hat{g}_R(l - \theta m + \phi n, n)$$

$$S'(R, \theta, \phi) = \left[F^{-1} \left[DFT[R(l, m, n)] \cdot DFT[\hat{S}'(l, m, n)] \right] \right]$$

既存モデル: PSC (ZDOCK*のモデル)

※既存モデル: PSC (ZDOCK*のモデル)
形状相補性スコアを複素数で表現
*Chen R, Weng Z. Proteins, 2003.

Receptor rPSC Ligand rPSC

ベンチマークデータ (44x44=1936) による網羅的 PPI 予測結果

ISLiM成果報告会2011

Y-axis: PPI X-axis: PPI

Color scale: No PPI (red) to Yes PPI (green).

Legend: R₁, R₂, R₃, ..., R₄₄

MEGADOCK (red line) vs random (black line) FP rate comparison plot.

MEGADOCK (red bar) vs ZDOCK2.1 (blue bar) True Positive (TP) comparison plot.

F-measure = $\frac{2 \cdot \text{TP}}{(\text{TP} + \text{FP}) + (\text{TP} + \text{FN})}$

既存アプリケーションとの性能比較

44タンパク質ペア (PPD Benchmark 2.0) | 対する実験結果

1ペアの平均ドッキング計算時間

ISLiM成果報告会2011

Y-axis: 正解ペア数 (44ペア中) X-axis: 計算時間 (秒)

Bar chart comparing average docking time for ZDOCK3.0 (~220s) and MEGADOCK2.1 (~50s). A red arrow points to MEGADOCK2.1 with the text "good". A blue arrow points to ZDOCK3.0 with the text "good". A red box highlights the difference as "約4倍の計算速度".

ZDOCK3.0 MEGADOCK2.1

ISLiM成果報告会2011

Y-axis: 正解ペア数 (44ペア中) X-axis: 計算時間 (秒)

Bar chart comparing true positive rates for ZDOCK3.0 (~20%) and MEGADOCK2.1 (~25%). A red arrow points to MEGADOCK2.1 with the text "good". A blue arrow points to ZDOCK3.0 with the text "good". A red box highlights the difference as "同等以上のドッキングの精度".

ISLiM EGFRシグナル伝達系既知パスウェイの再構築による評価

- 超大規模解析(約25万件)の解析を完了
 - 497セプター対497リガンド
 - =247,000構造ペア
 - 高い精度を示した
 - Precision (適合率) 0.29
 - Recall (再現率) 0.47
 - F-measure 0.36

25万規模の大規模な差問題への適用においても、細菌走化性系(1万規模)での結果と同等の精度を得た

	正解ペア	不正解ペア
Positive判定	53	131
Negative判定	59	747

同じタンパク質のデータを縮約

ISLiM 今後のチューニング課題

ドッキング計算部分について詳細プロファイルを取得

計算時間のかかっている部分
浮動小数点演算待ち
浮動小数点演算待ち
4~1命令
コミット
0命令
コミット

-5.0E-01 Thread 0 Thread 1 Thread 2 Thread 3 Thread 4 Thread 5 Thread 6 Thread 7

* 計測値は整備中のシステムによる暫定的な数値です。(2011年11月計測)

(1) FFTW (現在)、(2)FFTE、(3)Conv3D

ISLiM成果報告会2011

ISLiM 生物学の実問題への応用

- 細菌走化性シグナル伝達系
 - システム生物学における典型的な問題
 - 89構造を用いた89レセプター対89リガンド = 7921通りの計算

CheY CheD CheC CheA CheB CheW CheZ Tsr


Asp

“False positive”と評価した相互作用のうちCheY-CheDなど未知相互作用の提案を検討

赤太線:True Positive
青点線:False Negative
黒実線:False Positive

F-measure : 0.44

ISLiM成果報告会2011



1OPetaで挑む応用課題

ISLiM 肺がん関連パスウェイと薬剤関連タンパク間の
新規相互作用探索

肺がん関連(EGFR系)の遺伝子ネットワークに属する
タンパク質群を対象とした網羅的PPI予測

既知パスウェイ


既知タンパク質 (約1500立體構造)

294タンパク質 (約1500立體構造)

肺がん葉関連遺伝子(東大
宮野研究室提供)に関する
タンパク質データ

ISLiM成績報告会2011

ISLiM成績報告会2011



謝 辞

ISLiM

- 結果の一部は、理化学研究所が実施している
京速コンピュータ「京」の試験利用によるものです。
- 「京」における計測値は整備中のシステムによる暫定的な
数値です。(2011年6, 9, 11月計測)

ISLiM成績報告会2011

LiSDAS: データ同化計算技術に基づく 生体情報シミュレーション

樋口知之
次世代計算科学研究開発プログラム
データ解析融合研究開発チーム



発表者紹介

- 1989年 3月 東京大学理学系研究科地球物理学博士課程修了
1989年 4月 統計数理研究所予測制御研究系予測理論研究部門助手
1994年 12月 統計数理研究所予測制御研究系予測理論研究部門助教授
2002年 7月 統計数理研究所予測制御研究系システム解析研究部門教授
2004年 4月 統計数理研究所モデリング研究系教授, 予測発見戦略研究センター
副所長(兼務) (~2010. 3)
2011年 4月 統計数理研究所 所長

研究分野

- ベイジアンモデリング, データ同化

統計数理研究所
The Institute of Statistical Mathematics


I. ソフト研究開発の背景・目的

モデリングの制約

- ・タンパク質相互作用や転写因子データベースにもとづく反応経路拡張型モデルinguageの限界(組み合わせ爆発)
- ・モデリングの対象である分子リストが不完全なため、閉じた系として記述できない

実験の制約


- ・細胞の環境依存性や生体内分子のバリエーションならびに個体間の遺伝的差異
- ・等がもたらす化学反応の多様性
- ・個体ごとに異なる生化学パラメータやネットワークプロファイル

実験とモデリングの知識循環から永続的なモデル改良が必要である

LiSDAS: データ同化計算技術に基づく生体情報シミュレーション

統計数理研究所・所長
樋口知之

統計数理研究所・データ同化研究開発センター
吉田亮 中野慎也 長尾大道 斎藤正也



ISLiM成果報告会 2011

LiSDASが提供する機能

生体内分子の計測データを参照値としてあたえることで、シミュレーションの再現性、予測力を改善するためのパラメータチューニングやモデルの改良を行う。

モデリング

実験・計測

ISLiM



シミュレーション
モデル設計
評価と選択
モデルの再構成

仮説構築
薬剤応答性の予測
実験のデザイン

ISLiM

ISLiM

ISLiM 統計数理研究所

統計数理研究所
The Institute of Statistical Mathematics

ベイズ推定

$$p(\theta | y_{1:T}) \propto p(\theta) \cdot p(y_{1:T} | \theta)$$

Prior Belief about values of x

Likelihood Feasibility of realization of y for given x

Posterior Improved knowledge about values of x

ISLiM 統計数理研究所

統計数理研究所
The Institute of Statistical Mathematics

計算手法

基底測度 $G_0(\pi)$

観測時系列を分析して設計する

サンプリング π_i

シミュレーション

サンプリング $\theta_j | \pi_i$

尤度による重み付け

観測データ D

改良された分布 $G(\pi)$

$$P(\pi | \Pi_n, \mathbf{D}, \gamma) = \frac{1}{n + \gamma} \sum_{i=1}^n w_i \delta_{\pi_i}(\pi) + \frac{\gamma}{n + \gamma} G_0(\pi)$$

$$w_i \propto m^{-1} \sum_{k=1}^m P(\mathbf{D} | \theta_k) \text{ with } \theta_k \sim P(\theta_k | \pi_i)$$

(手順の詳細はペスターを参照)

ISLiM 統計数理研究所

統計数理研究所
The Institute of Statistical Mathematics

III. 現時点でのソフト研究開発成果

テスト問題: 哺乳動物の概日周期転写ネットワーク

- モデルの構成
- システム変数の個数: 29
- 観測変数の個数: 7
- モデル/ラメータ数: 116

ISLiM 統合生物学研究所

統合生物学研究所
The Institute of Integrative Biology

LiSDASiにおける細胞内生化学反応のモデル

翻訳

転写

遺伝子



転写因子の結合 (転写を促進または抑制する)

mRNA の寿命 ~ 10 min to over 10 h

~ 30 min

~ 30 min

~ 10 min to over 10 h



ISLiM 統計数理研究所

データ同化ライブラリ適用事例：
線虫初期胚における細胞内流動データ同化
(遺伝研 木村研究室(細胞建築学)との共同研究)

Model parameters:

- velocity of the cell wall how to design $u_{wall}(L, t)$
- viscosity coefficient
- density

EnKF

- search model parameter maximizing the likelihood
- observed velocity field

MCMC

- obtain posterior distribution (multi peaked pattern?)

Fig. 1 線虫初期胚の細胞質流動の模式図

ISLiM 統計数理研究所

啓発活動

企画・総説執筆

データ同化センターの紹介ビデオ (10分) を作成しました。YouTubeにアップしています。

ISLiM 統計数理研究所

シミュレーション結果

モデルの規模: シミュレーション変数46個, 細胞内流動変数 17,654個 (詳細はボスターで)

- 大局部には、観測データをよく再現する。一方、□部分のように、観測に反する遺伝子群も残されている。

時間 (最大値: 48時間)

PC9-GFT :: Time series data

PC9-GFT :: Simulation

PC9GR-GFT :: Time series data

PC9GR-GFT :: Simulation

全17654遺伝子

ISLiM 統計数理研究所

IV. プロジェクト終了時のソフト研究開発の達成目標

- 肺がん細胞の薬剤応答を適用例としてLiSDASの開発を進めた。しかし、現状のモデルでは、一部の遺伝子群について発現パターンを再現しない。生物学的な知識を追加することで、改良を進めめる。
- モデルの改良にともなうモデル規模の拡大が予想される。モデル規模が拡大した場合の対応(性能的な意味)を行う。
 - 最終的なパラメータ数: 368 → 500
 - 内生変数: 17654 (=遺伝子の総数) → 17654 + α
 - 10,000ノードを超えると、通信負荷による並列性能の低下が目立つてくる。アルゴリズムを見直し、30,000ノードまで線形に近い合数効率の実現することを目指す。
 - 肺がん細胞の薬剤応答モデルの構成法は一般に利用できるものである。現時点の実装では、LiSDASの外部にあるが、これを本体に組み込むことで利便性を向上させる。

謝辞

京での計算に関しては京遠コンピュータ京の試験利用、および本年3月での特別運用での結果です。また、PCクラスタでの性能計測に関しては理化学研究所情報基盤センターのRICCを 使用しています。

(謝辞)

本資料集に記載されている「京」での計算は、2011 年 3 月の「京」の特別運用およびその後の試験利用によって行われたものです。

また、本資料集に記載されている「京」を使用した測定値は、開発整備中の「京」による、測定時点での数値です。