

ビッグデータ創薬・AI創薬

ビッグデータから人工知能を用いて
創薬・DRを行う

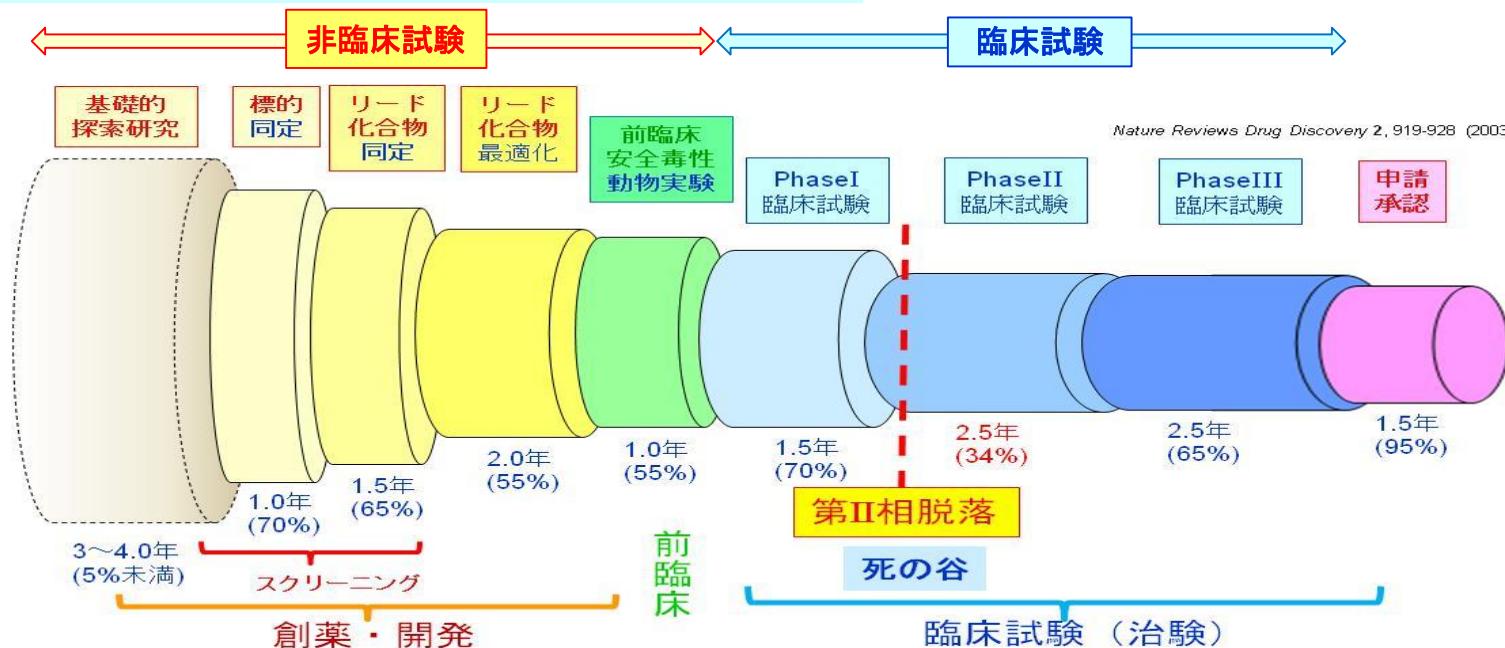
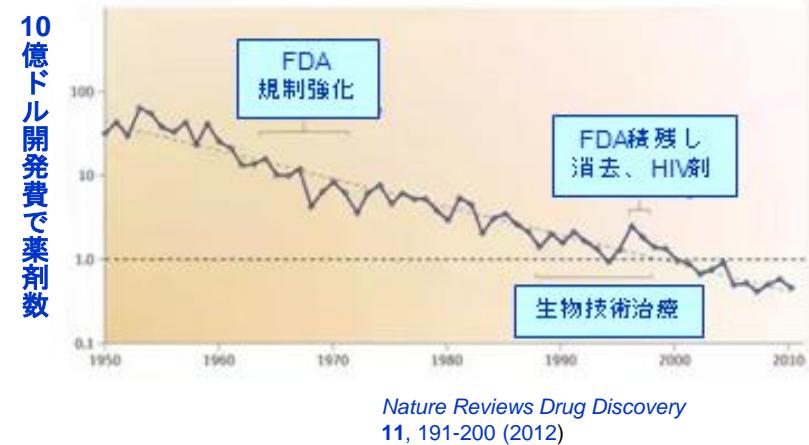
東京医科歯科大学
東北大学 東北メディカル・メガバンク機構

田中 博

第一部 ビッグデータ計算創薬

創薬をめぐる状況

- 医薬品の開発費の増大
 - 1医薬品を上市するのに約1000億円以上
- 開発成功率の減少
 - 2万~3万分の1の成功率
 - とくに**非臨床試験**から**臨床試験**への間隙
 - phase II attrition** (第2相脱落)
- 臨床的予測性
 - 医薬品開発過程の**できるだけ早い段階**での**有効性・毒性の予測**
- 臨床予測性の早期での実施
 - 罹患者のiPS細胞を使う
 - ヒトの薬剤・生体関連のビッグデータを使う



ドラッグ・リポジショニング

薬剤適応拡大

ヒトでの安全性と体内動態が十分に分かっている
既承認薬の標的分子や作用パスウェイなどを、体系的・論理的・網羅的に解析することにより新しい
薬理効果を発見し、その薬を別の疾患治療薬として
開発する創薬戦略

利 点

- (1) 既承認薬なので、ヒトでの安全性や体内動態などが既知で臨床試験で予想外の副作用や体内動態の問題により開発が失敗するリスクが少なく**開発の成功確率が高い**
- (2) 既にあるデータや技術（動物での安全性データや製剤のGMP製造技術など）を再利用することで、**開発にかかる時間とコストを大幅に削減できる**
- (3) **DR候補探索に疾患生命情報ビッグデータ知識DBを使用できる。**

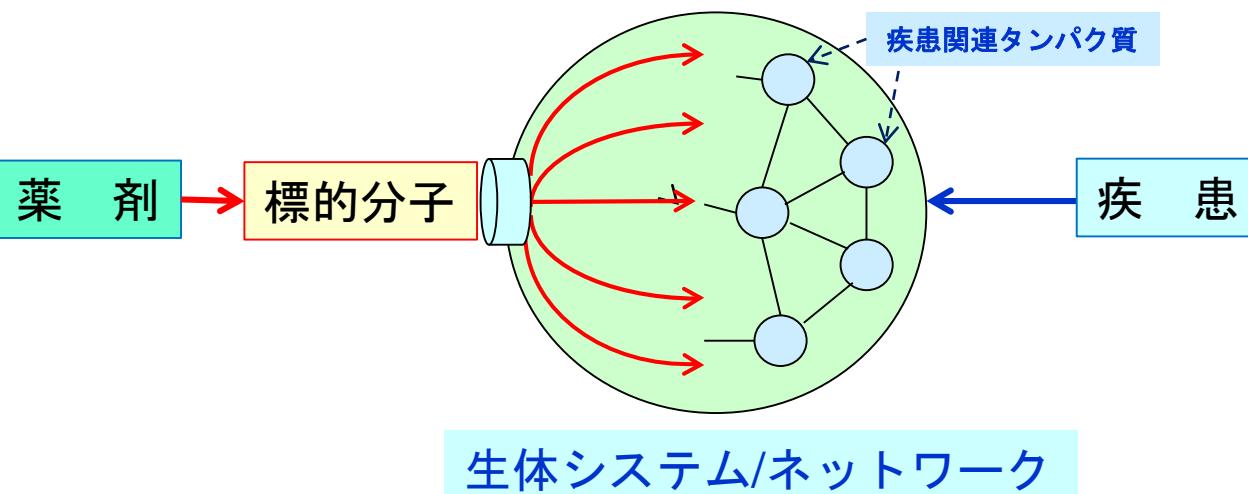
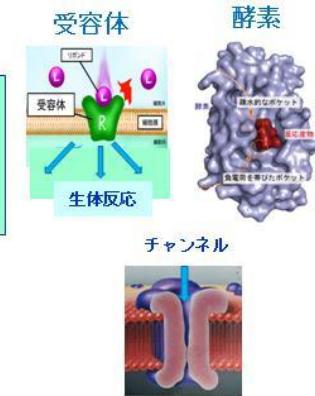
疾患・薬剤・標的の関係

病気の主要な要因

疾患要因タンパク質（複数）

薬：疾患要因タンパク質に影響を示す
標的タンパク質に作用し阻害する

薬剤の標的分子
受容体・酵素・チャネルなど



生体システム/ネットワーク

ビッグデータ計算創薬 1

計算創薬(*in silico*創薬)の新しい方向

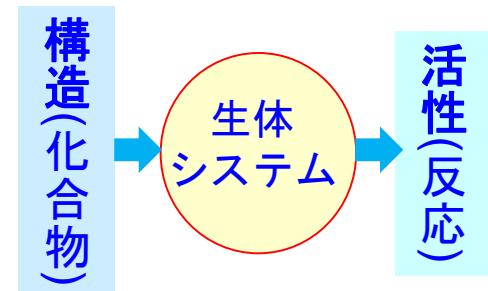
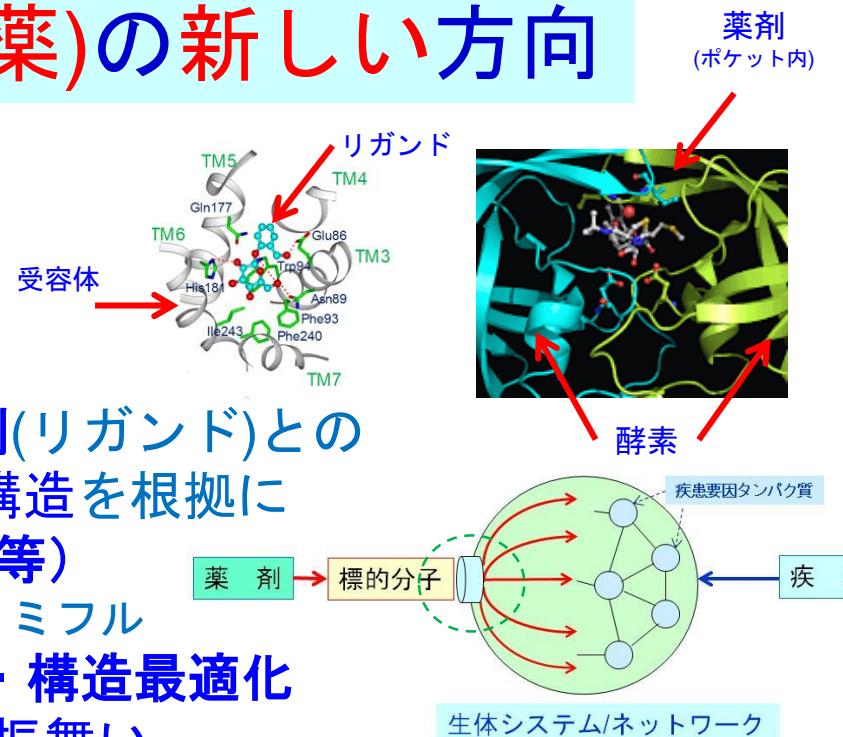
これまでの計算創薬

分子(結合構造)中心

- 分子構造解析・分子設計
- 標的分子(受容体・酵素)と薬剤(リガンド)との結合構造(ポケット)の分子構造を根拠に
- リガンドの分子設計(量子化学等)
 - 成功例: インフルエンザ薬 タミフル
- 標的に結合するリード化合物・構造最適化
- 結合後の生体システムの反応/振舞い
明確な取扱いがない

定量的構造活性相関(QSAR)

- 化合物の分子構造と生体活性の関係
- 両者の間には生体システムがある



ビッグデータ計算創薬 2

新しい計算論的創薬のアプローチ(網羅的分子プロファイル創薬)

疾患罹患状態における

疾患関連遺伝子/タンパク質に起因し決定される

疾患時の生体のゲノムワイドな特異状態

疾患特異的な網羅的分子プロファイル変化

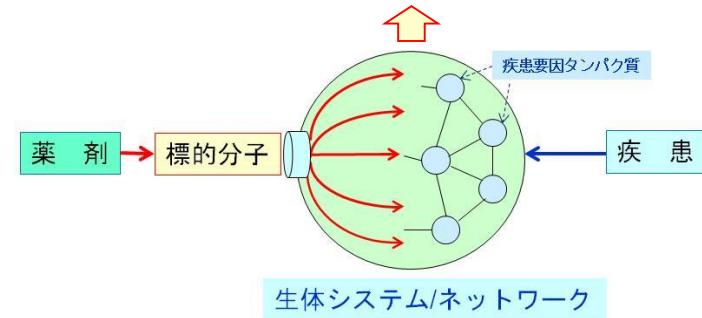
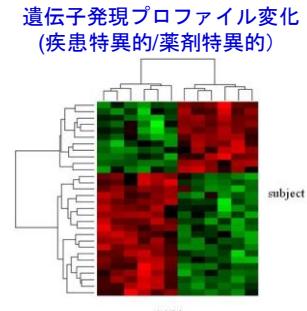


薬剤投与による

標的分子と薬剤分子の結合に起因し起こる

投与時の生体のゲノムワイドな反応/振舞い

薬剤特異的な網羅的分子プロファイル変化



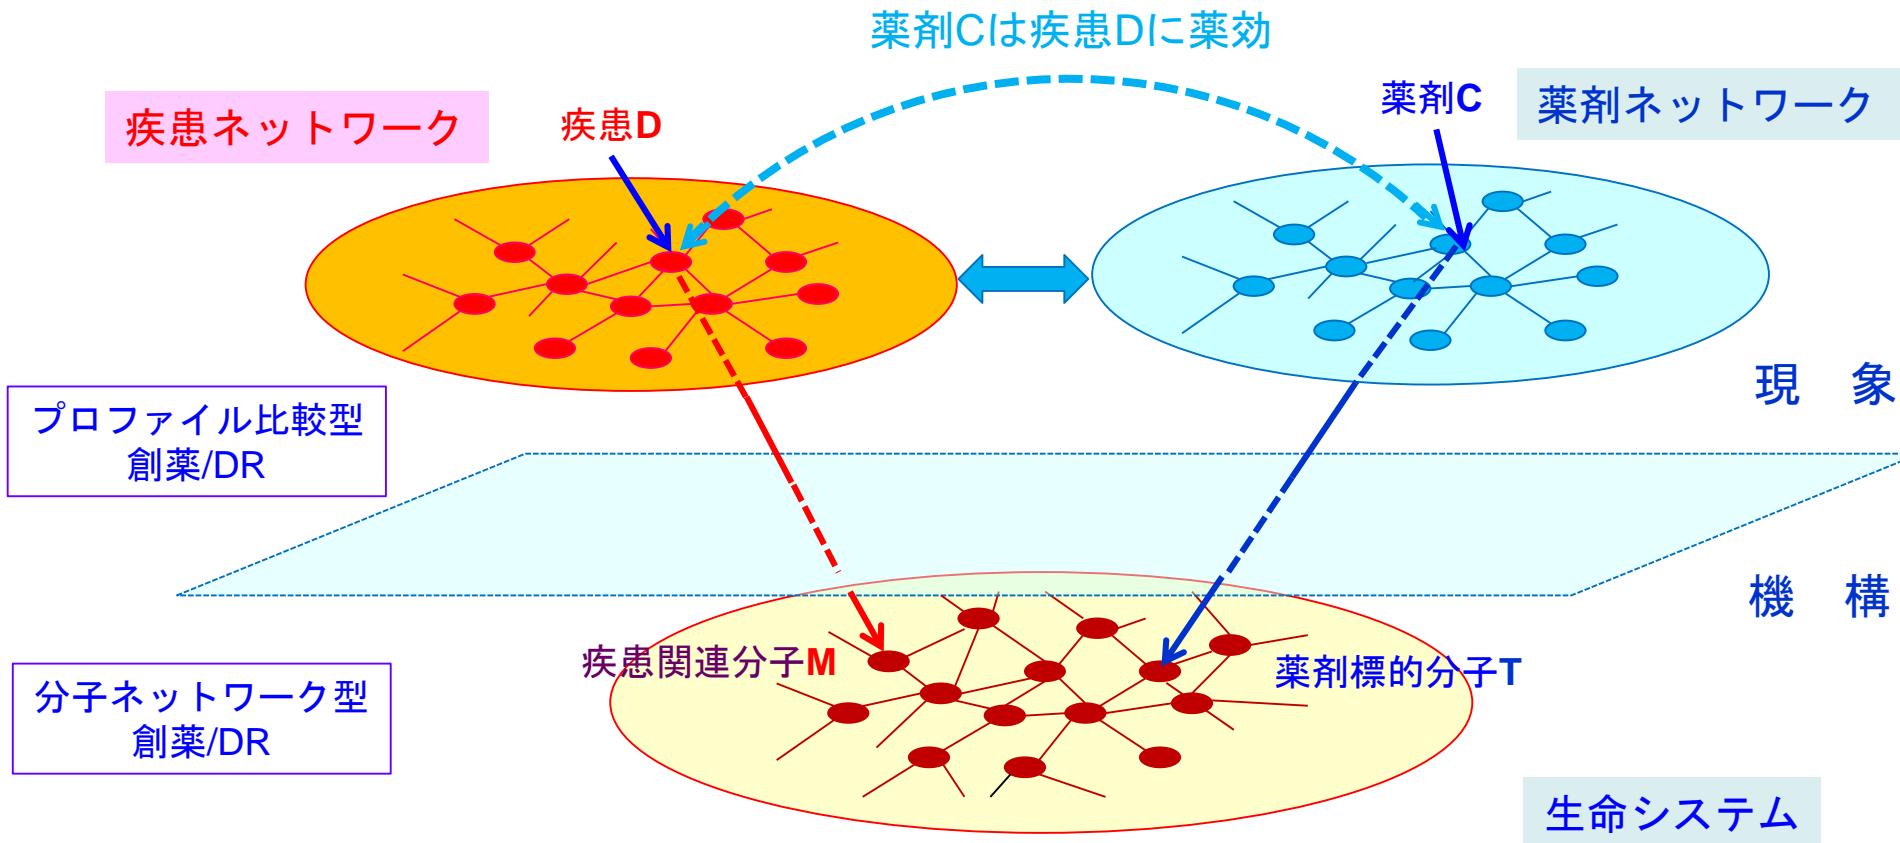
網羅的分子プロファイル⇒分子ネットワーク全体変化

<疾患状態の生体>に<薬剤一標的分子の結合>を引き起す作用によって
ゲノムワイドな 生体分子環境がどう変化するか 「生命システム観点からの理解」

化合物, 標的分子, 疾患間の関係の「ビッグデータ」DBを利用

プロファイル型計算創薬の原理

3層生体・薬剤ネットワークのFramework



1. 遺伝子発現プロファイル比較型 創薬・DR

ビッグデータ計算創薬 発現プロファイル比較型創薬・DR

• 薬剤特異的遺伝子発現

– CMAP(Connectivity Map)

- 薬剤投与による遺伝子発現プロファイル変化
- 米国 ブロード研究所, 1309化合物,
5種類のがんの培養細胞
約7000 遺伝子発現プロファイル
- シグネチャ (署名) 差異的発現遺伝子代表群
- DB利用：シグネチャを「問合せ」：
類似性の高い順に化合物を提示
- 最近はLINCS：100万種の薬剤特異的発現DBが存在

• 疾病特異的遺伝子発現

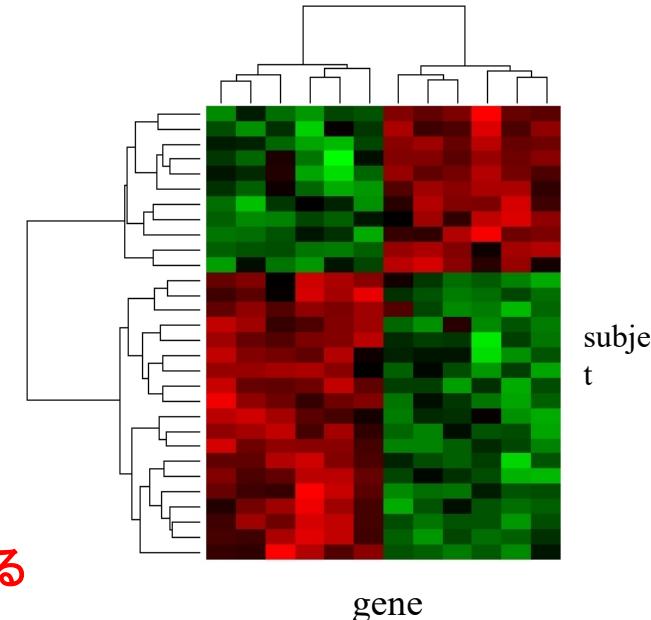
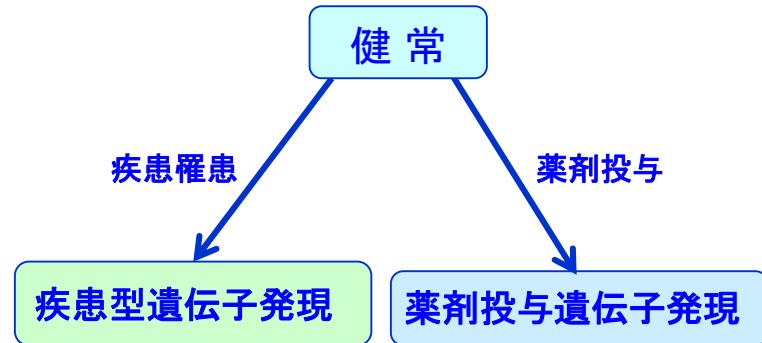
– GEO (Gene Expression Omnibus),

- 疾病罹患時の遺伝子発現プロファイルの変化
- 米国NCBI作成・運用 2万5千実験,
70万プロファイル (欧州 ArrayExpress)
- もEBIが作成、サンプル数同程度

基礎には分子ネットワークの疾病/薬剤特異的变化

遺伝子発現プロファイル変化

≈ 分子ネットワーク活性構造変化を反映する

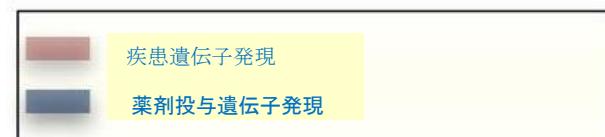
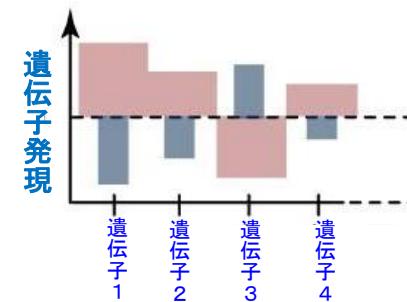
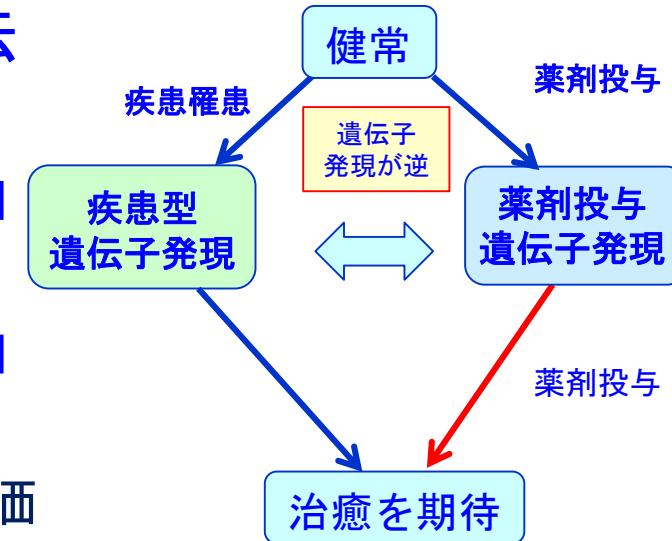
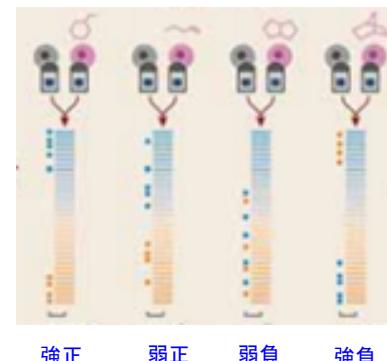


遺伝子発現プロファイルによる有効性予測

- 遺伝子発現シグネチャ逆位法
 - 疾患によって健常状態から変異「疾患特異的遺伝子発現プロファイル」
 - これに薬剤投与の変化を起こす「薬剤特異的遺伝子発現プロファイル」
 - 両者のパターンが負に相関する
 - ノンパラメトリックな相関尺度で評価
- 効果が相加的なら有効性が期待される
 - 例：炎症性腸疾患に抗痙攣剤(topiramate), 骨格筋委縮にウルソール酸

ベースは疾患遺伝子発現
横の点は薬剤遺伝子発現

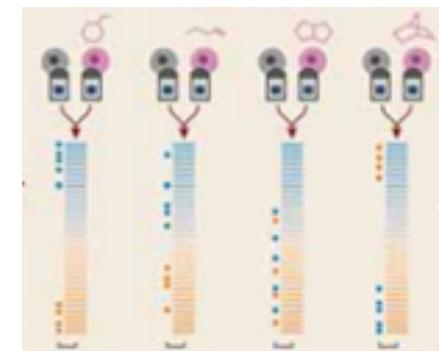
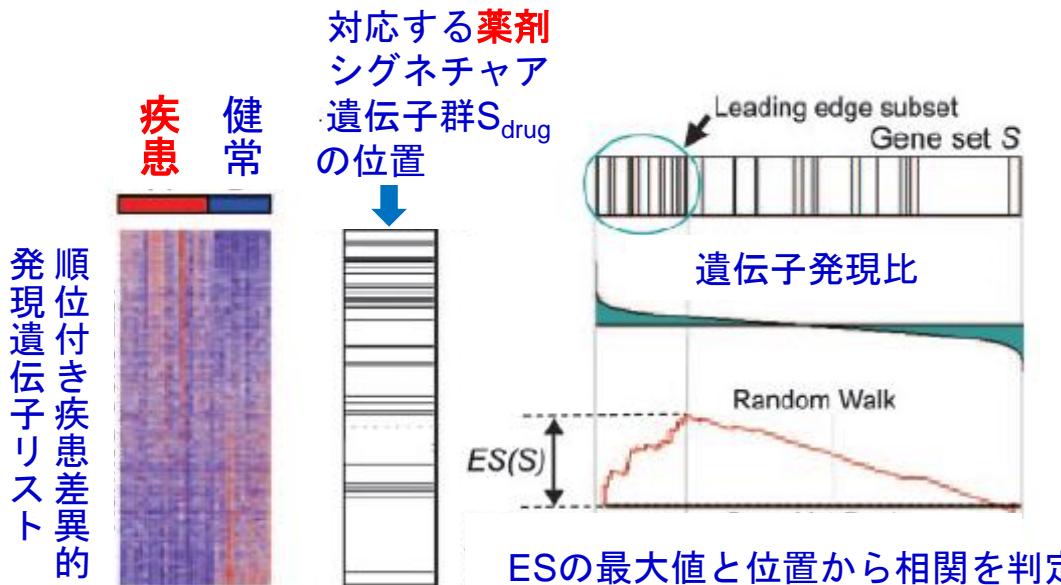
青は発現が上昇した遺伝子
赤は発現が下降した遺伝子



Non-parametric な相関尺度で評価

Gene Set Enrichment Analysis (GSEA)

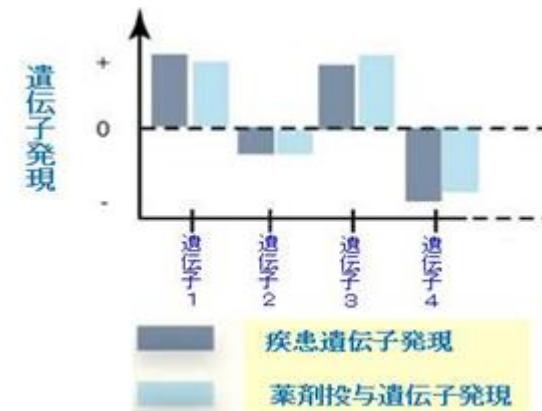
- 対照と比較して順位づけられた遺伝子リストの上位に密集しているかの尺度



発現比ランクの高い順から遺伝子を調べ
遺伝子リスト S_{drug} 中に該当する遺伝子が存在し
たら ES (Enrich Score) を加算、無ければ減算

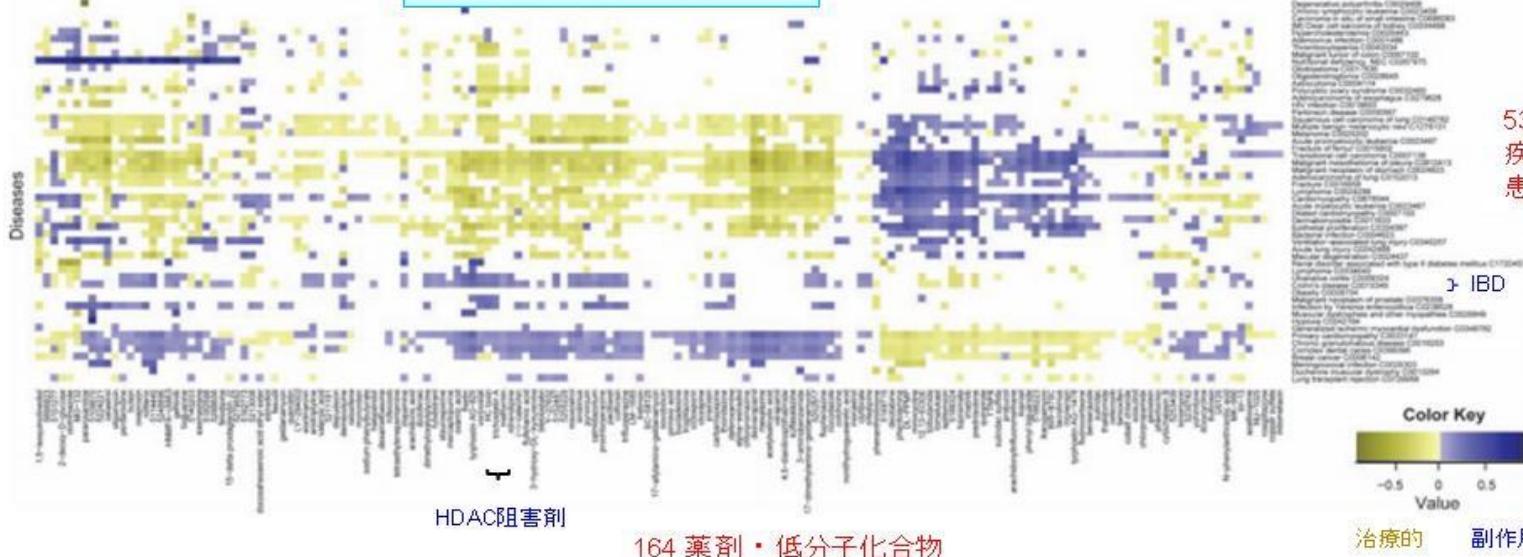
遺伝子発現プロファイルによる毒性予測

- 連座法 guilt-by-association :
- 薬剤一疾患間 副作用予測
 - 薬剤特異遺伝子発現プロファイルと
 - 疾患特異的遺伝子発現プロファイルが
 - ノンパラメトリック正に相関
 - 毒性・副作用の予測



疾患-薬剤マップ

(Sirota, Butte 2011)



発現プロファイル原理による <疾患-薬剤 Map>に基づく計算DR

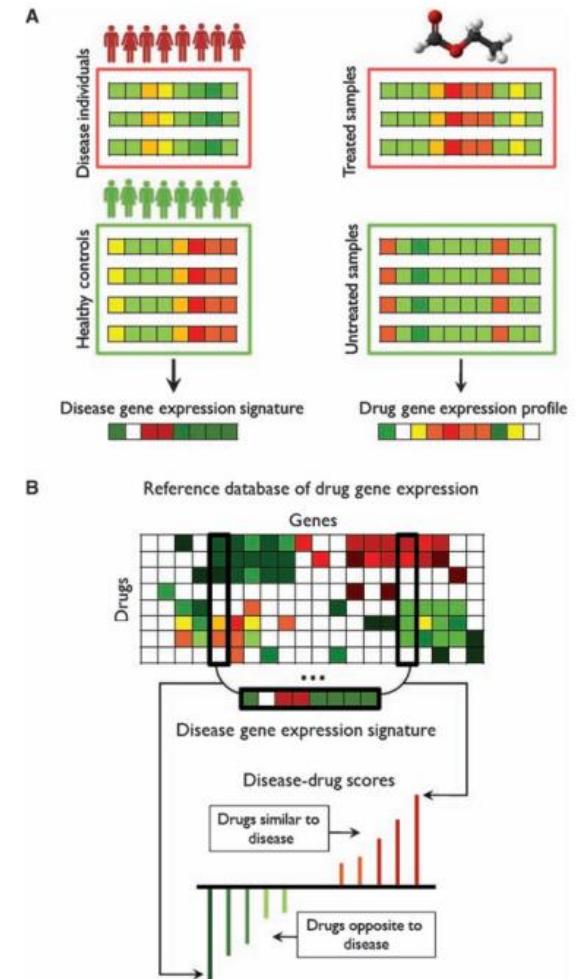
- NCBI・GEOから100疾患のシグネチャを取得
- c-Mapより得た164の薬剤・化合物の薬剤特異的遺伝子発現プロファイル 疾患-薬剤間で類似性スコアを計算
- 約16000組の疾患-薬剤間の2664組が有意、半数以上が治療的関連(負)あり
- 100疾患内、53疾患有意に164薬剤と関連

Table 1. Drugs and diseases with the most indications.

Drugs with most indications		Diseases with most indications	
Vorinostat	HDAC阻害剤	21	Transitional cell carcinoma 95
Gefitinib		18	Melanoma 79
HC toxin		18	Cardiomyopathy 73
Colforsin		17	Adenocarcinoma of lung 72
17-Dimethylamino-geldanamycin		16	Multiple benign melanocytic nevi 68
Trichostatin A		16	Squamous cell carcinoma of lung 67
3-Hydroxy- α -kynurenine		15	Malignant neoplasm of stomach 66
5114445		15	Dermatomyositis 63
Dexverapamil		15	Malignant mesothelioma of pleura 53
Prochlorperazine		15	Primary cardiomyopathy 48

Drug group	Drugs
PI3K inhibitors	LY-294002 and wortmannin
HSP90 inhibitors	Geldanamycin, raloxifene, monorden, and sodium phenylbutyrate
HDAC inhibitors	Vorinostat, HC toxin, and trichostatin A
Salicylate and anti-inflammatory agents	Sulfasalazine, mesalazine, and acetylsalicylic acid

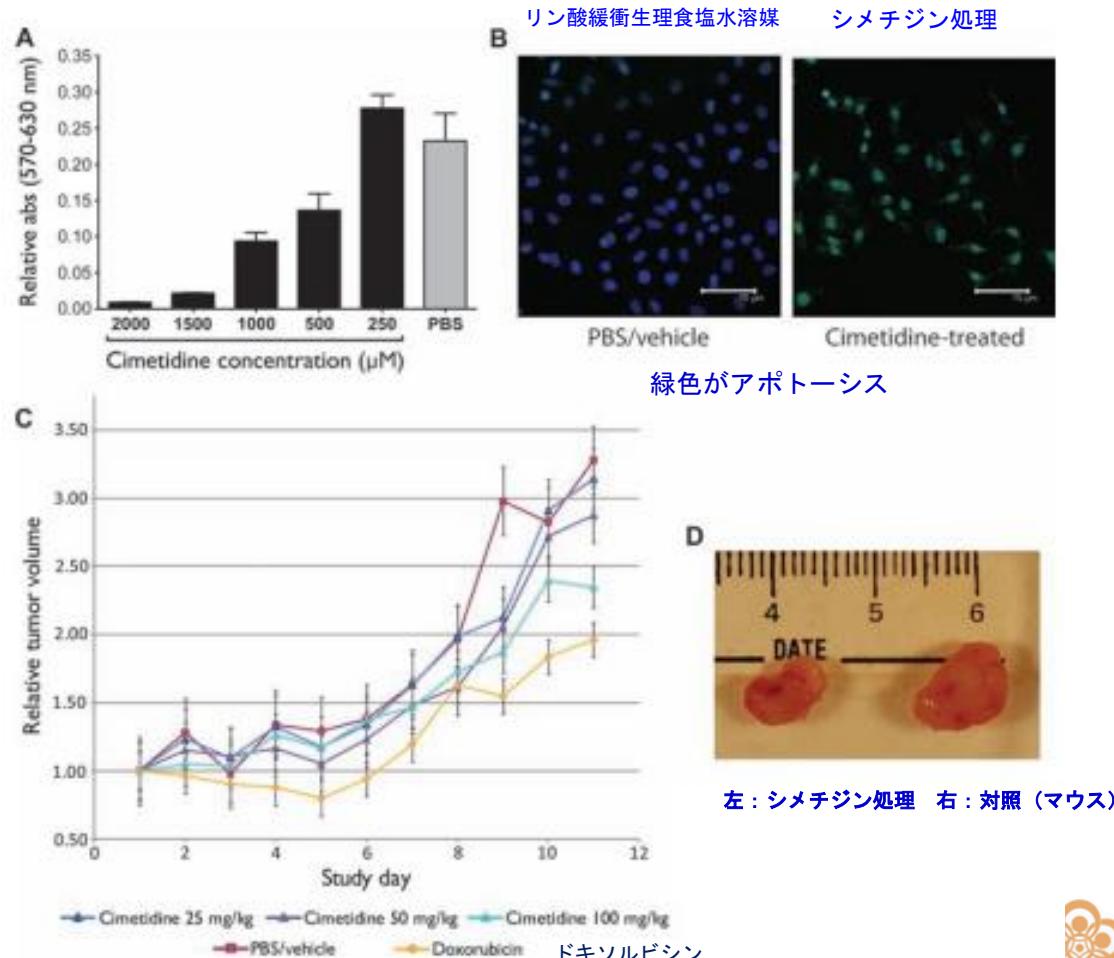
Canonical	Noncanonical
Cancers	Crohn's disease and lung transplant
Ulcerative colitis and Crohn's disease	Polycystic ovary and glioblastoma
	Cardiomyopathy and cancer



(Sirota, Butte 2011)

動物実験での実証

シメチジン(cimetidine:ヒスタミンH2受容体拮抗薬) →肺腺癌(LA)に有効か
予測スコア -0.088 であったが gefinitib の-0.075より高い



遺伝子発現Profilingによる疾患-薬剤ネットワーク (Hu, Agarwal)

遺伝子発現プロファイル(c-Map)での相関係数、ES指標によりネットワーク表示

疾患-疾患、薬剤-薬剤、疾患-薬剤の
ネットワークを発現プロファイルより構成

疾患 - 疾患 (disease-disease) 645 組

疾患-薬 (disease-drug) 5008 組

薬 - 薬 (drug-drug) 164,374 組

結果

①疾患関連の60%はMeSH (既知体系)

その他は分子レベル疾患分類学

Transcriptomeの類似性による疾患体系

②主な発見

<疾患 - 疾患>

HSP (Hereditary Spastic Paraparesis)

(遺伝性痙攣性対麻痺)

→ bipolar 双極性障害 --精神障害も

Solar keratosis 日光性角化症

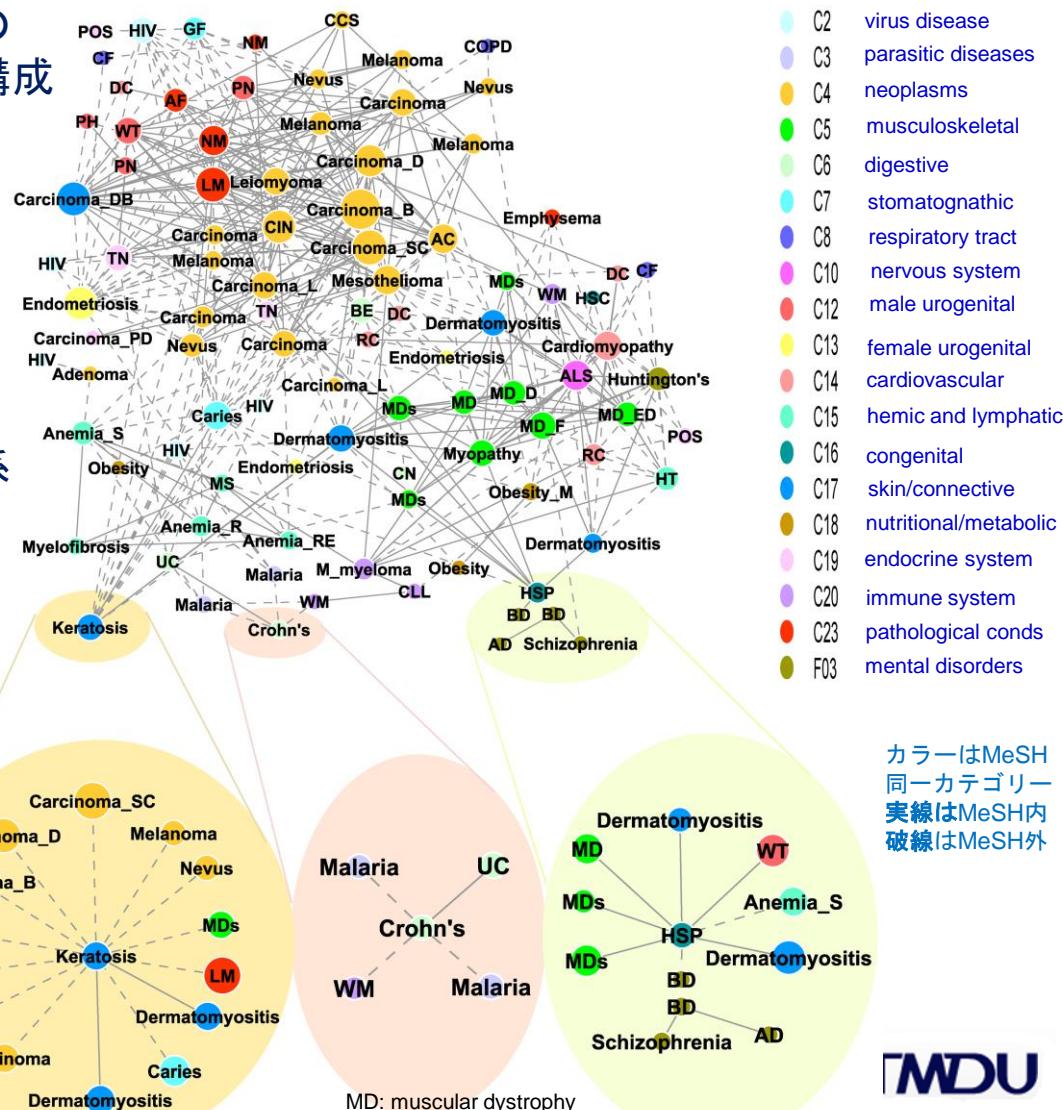
→ cancer(squamous) --前癌段階

<疾患 - 薬>

有効性 : マラリア治療薬

→ Crohn's disease

ハンチントン病に種々の薬剤



遺伝子発現 Profiling による Drug-Diseaseネットワーク

疾患－薬剤および薬剤－薬剤ネットワーク
(Disease-drug network:右図)

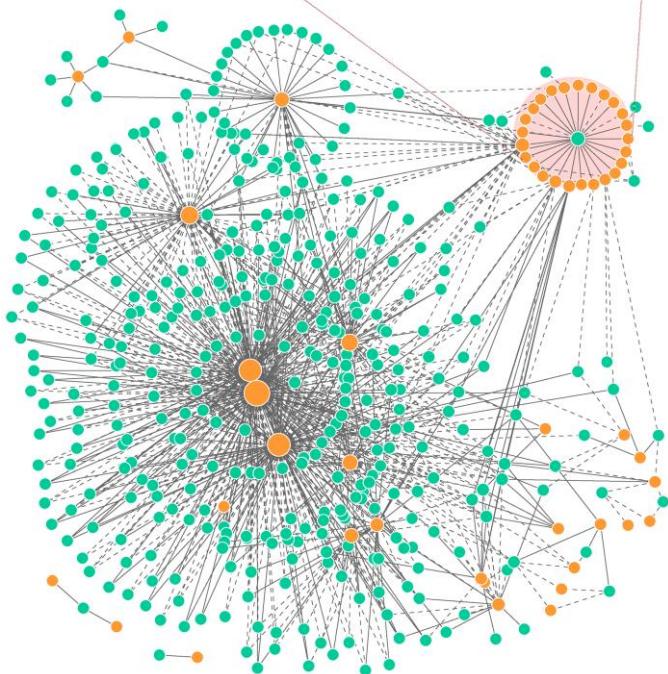
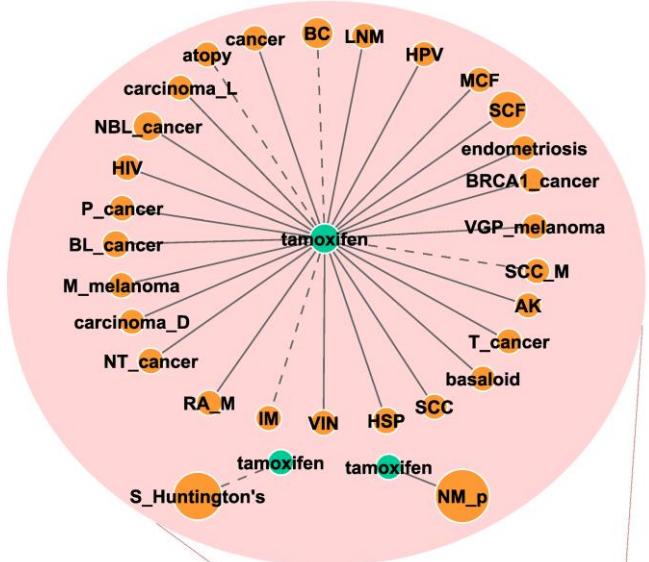
橙色節 49 疾患, 緑色節 213 薬剤

906 疾患－薬剤結合
実線 正値 破線 負値

Tamoxifen (breast cancer)
有効性 負の値をもっている

⇒アトピー,
⇒マスト細胞分泌抑制、
アレルギー抑制

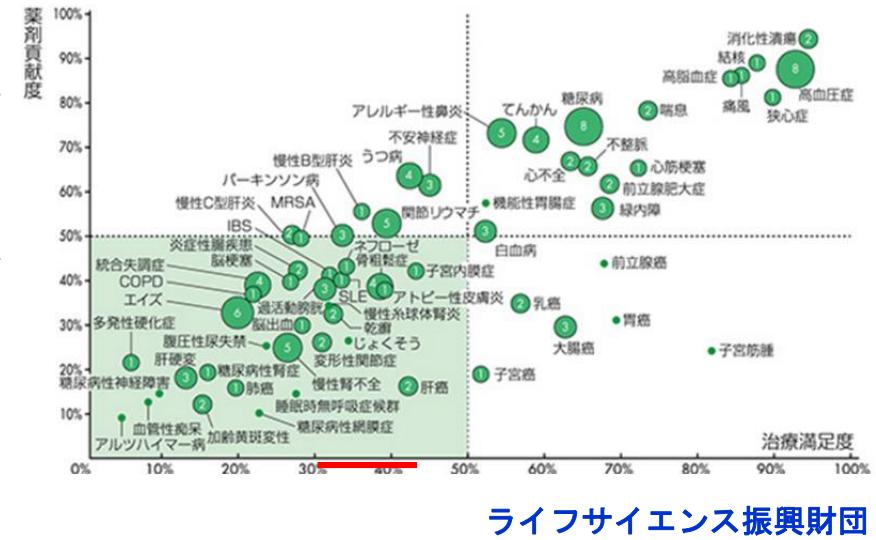
Hunting病に多数のDR薬
副作用 正の値をもっている
副作用の予測
⇒ 発癌性



疾患－薬剤ネットワーク

我々の研究室での成果

- 対象疾患 (Sibata et al. 2015)
 - 薬剤貢献度と治療満足度がともに低い糖尿病性網膜症 (diabetic retinopathy) の薬剤探索
- 方法
 - Signature revision法を適用
 - 疾患特異的遺伝子発現
 - GEOから糖尿病性網膜症の遺伝子発現プロファイルを収集 (GSE53257)
 - 対照：16サンプルの健常例
 - 206遺伝子 疾患signature を確定
 - 130 up-regulated
 - 76 down-regulated genes
 - cMAPより疾患と負値ESの薬剤特異的発現を提示する有意な薬剤を探索
- 結果
 - 1600組のなかで37組の<疾患 - 薬剤>が有意、その中でも **11剤が負値のES**
 - FDR (*q*値) <0.005
 - thapsigargin (score -0.983, p-value 0.00002), alprenolol (score -0.892, p-value 0.00026), ionomycin (score -0.896, p-value 0.00208), phenylpropanolamine (score -0.814, p-value 0.00219)など
- 考察
 - thapsigargin : endoplasmic reticulum (ER) ストレスに関与。ER stress は NF- κ B を活性化
 - 糖尿病性網膜症は本質的には炎症反応
 - NF- κ B は the unfolded protein response (UPR) で制御されている。
 - ER stress がこの炎症の制御に役立つ可能性がある



	薬剤	SCORE	p 値
1	thapsigargin	-0.983	0.00002
2	alprenolol	-0.892	0.00026
3	ionomycin	-0.896	0.00208
4	phenylpropanolamine	-0.814	0.00219
5	etiocholanolone	-0.621	0.00961
6	kinetin	-0.72	0.01249
7	triflupromazine	-0.706	0.0155
8	vanoxerine	-0.681	0.02274
9	cicloheximide	-0.657	0.03185
10	khellin	-0.579	0.03975
11	rotenone	-0.625	0.04852



TMDU

近年のビッグデータ化 LINCS

- **LINCS** (library of Integrated network-based cellular signatures)
 - GE-HTS(gene expression high throughput screening)の1つ
 - 摂動（化合物添加）を与え調節系を介して、細胞表現型を観察する
 - 遺伝子発現変化⇒差異的発現 **signature**
 - cMAP (2006, Lamb)に比べてスケール拡大
 - cMAPは、4つの細胞系列～1300化合物 FDA認可薬剤 Micro array (mRNA) Affymetrix U 113で遺伝子発現測定
- NIHから助成, **100万の遺伝子発現プロファイル**を **L1000** 技術で測る
 - Broad Institute cMAPと同じメンバーが考案
 - 1000遺伝子の発現しか測定しない ゲノムワイドな遺伝子発現プロファイル（～全遺伝子 22000 genesの発現）をGEOから作ったモデルで推定する
 - 相互依存性高い⇒1000遺伝子にすべて情報が含まれている
- **L1000技術**
 - 細胞溶液からリガンド媒介増幅によってmRNA増幅
 - 遺伝子特異的なProbeはcDNA (mRNA)にtaqリガーゼでアニールする
 - ProbeはPCRで増幅され、ルミネックスビーズと遺伝子特異的部分で対形成する
 - 対形成した差異染色ビーズはレーザを用いて検出され定量化される
 - ビーズの上の対形成したprobeの密度を測る 80の恒常的発現校正遺伝子
- **22412 摂動遺伝子発現**
 - 56 細胞コンテキスト（ヒト初代培養細胞、がん培養細胞）について
 - 16425 化合物、薬剤
 - 5806 遺伝子ノックアウト(RNAi, miRNA)、過剰発現
 - 総計で100万ぐらい遺伝子発現プロファイルがある
- **Genometry** が**L1000™ Expression Profiling**技術でヤンセンと契約
 - 25万種類の化合物

LINCSの問合せ画面

--- LINCS Canvas Browser ---

Gene Lists

Up List
EEF1A2
UBE2S
FAM64A
FGFR1
PAXIP1
SPARC
SNRPA1
ADAMTS1
EIF4EBP1
PFKP
BTG2
CDK16
ERRFI1
ARPC4
IFI30

Down List

clear

clear

Up Down

Search Example Enrichr

Aggregate Reverse

Top 50 Concensus Experiments (Down/reverse)

Overlap	Info (Perturbation, Dose, Time, Cell, Batch)
0.5000	Tyrphostin AG 1478.56 78 µM 24 h A375 CPC006
0.5000	PD0332991.2 µM 24 h MDAMB231 LJP001
0.5000	PD0332991.10 µM 24 h MDAMB231 LJP001
0.5000	PD0332991.10 µM 24 h MCF10A LJP001
0.5000	Aminopurvalanol A 10 µM 24 h PC3 CPC002
0.5000	3-(5-dichloro-2-hydroxyphenyl)benzenesulfonamide
0.4800	PD0332991.2 µM 24 h BT20 LJP001
0.4800	PD0332991.10 µM 24 h BT20 LJP001
0.4800	MLN2238.10 µM 24 h BT20 LJP001
0.4800	2-(6,6-dimethoxy-3-oxodienylcarbamoyl)phenyl 3.10 µM 24 h A375 CPC006

Showing 1 to 10 of 47 entries

Average Change - Time Point - Drugs - Dose

The heatmap displays the average change in gene expression across 47 experiments. The color scale ranges from dark red (downregulated) to light yellow (upregulated). A single red square highlights a specific experiment, likely corresponding to the one listed in the top 50 consensus experiments table.

IL1
100 ng/µL, 6 h
in BT20

contrast:

A horizontal slider labeled "contrast" with a central arrow pointing right, used to adjust the color scale of the heatmap.

Avg. Z-score:

Select a cell line:
BT20

Select a batch:
LJP004

Multiple Selections:

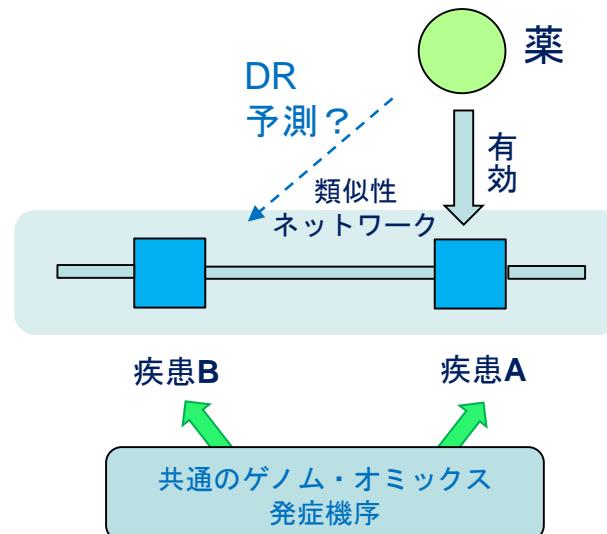
TMDU

2. 疾患ネットワーク創薬/DR

疾患ネットワーク空間を基礎にした
ビッグデータ創薬/DR
<疾患ネットワークでの近接性>

ビッグデータ創薬/DRの基本原理 2 疾患ネットワーク準拠創薬/DR

- ・ 従来の疾患体系 nosology
 - Linne以降300年に亘って表現型による疾病分類
 - 臓器別・病理形態学別の疾患分類学
- ・ ゲノム・オミックスレベルでの発症機構での疾患分類
 - 発症の内在的 (intrinsic) 機構の類似性を基準に
疾患ネットワーク (疾患マップ) をつくる
 - ゲノム・オミックスによる内在的疾病機序の概念が基礎



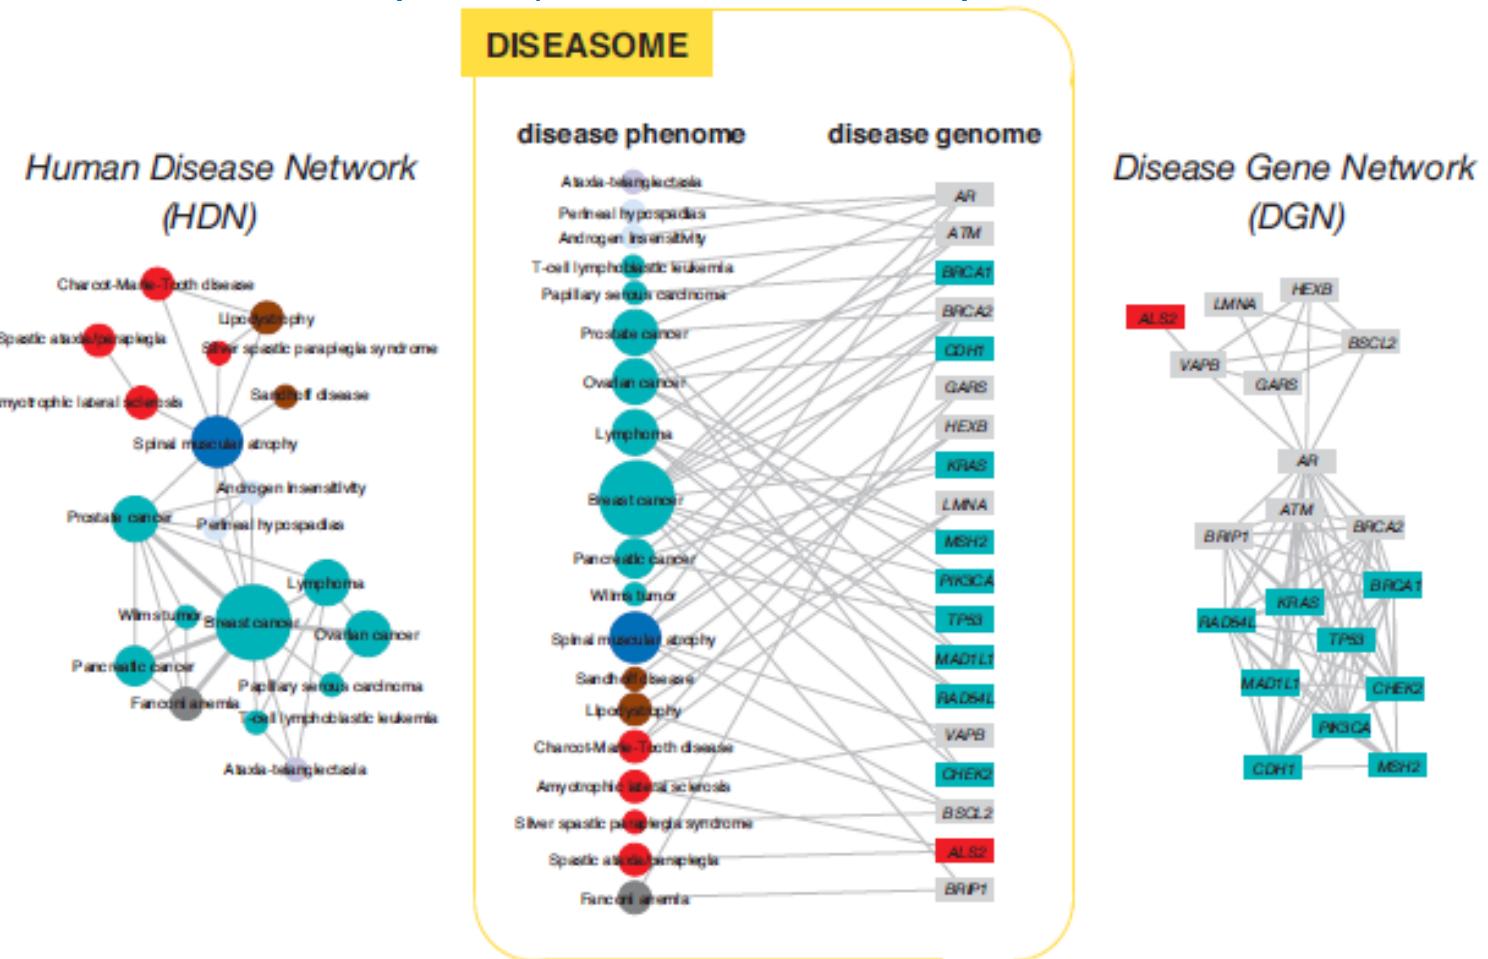
疾患形成のゲノム・オミックス機序

- 疾患関連遺伝子型（第1世代型）
 - 原因遺伝子、疾患感受性遺伝子の変異・多型が主要発症機序
- 疾患オミックス型（第2世代型）
 - 疾患オミックスプロファイルの変容が主要発症機序
 - Transdisease omics
- 疾患分子ネットワーク型（第3世代型）
 - 分子ネットワークの歪みが主要発症機序
 - がんなどで遺伝子型（肺腺がん等）でない通常のがん

第1世代型 Diseasomeと疾患遺伝子

- OMIMから 1,284 疾患と 1,777 疾患遺伝子を抽出
- ヒト疾患ネットワーク (HDN)
 - 867疾患は他疾患へリンクを持つ 細胞型や器官に非依存
 - 516疾患が巨大クラスターを形成
 - 大腸がん、乳がんがハブ形成
 - がんはP53 やPTENなどにより最結合疾患 がんなどは後天的変異
 - 疾患を網羅的に見る見方：臓器や病理形態学に非依存
 - リンネ（12疾患群分類）以来300年続いた分類学を越える
- 疾患遺伝子ネットワーク (DGN)
 - 1377遺伝子は他の遺伝子へ結合
 - 903遺伝子が巨大クラスター
 - P53がハブ
- ランダム化した疾患/遺伝子ネットワークに比べ
 - 巨大クラスターのサイズが有意に小さい
- 疾患遺伝子は機能的なモジュール構造
 - 同じモジュールに属する遺伝子は相互作用し
 - 同一の組織で共発現し、同じGO（遺伝子オントロジー）を持つ

疾患ネットワーク Diseasome (Goh,Barabasi et al.)



1つ以上の疾患関連遺伝子を共有する疾患

1つ以上の疾患を共有する疾患関連遺伝子

Kwang-II Goh*, Michael E. Cusick, David Valle, Barton Childs, Marc Vidal, and Albert-Laszlo Barabasi The human disease network PNAS2007



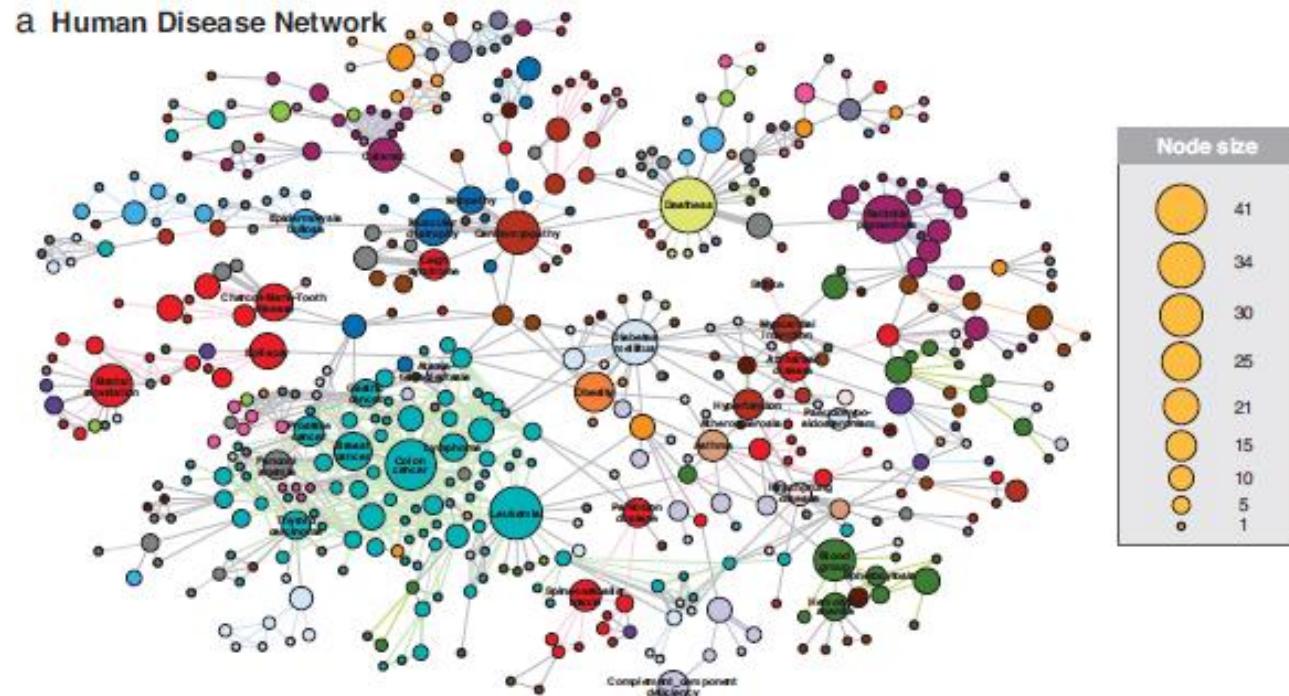
疾患 ネットワーク (HDN)

Nodeの直径

疾患に関与している原因
遺伝子の数に比例

リンクの太さ

疾患間で共有している
原因遺伝子の数

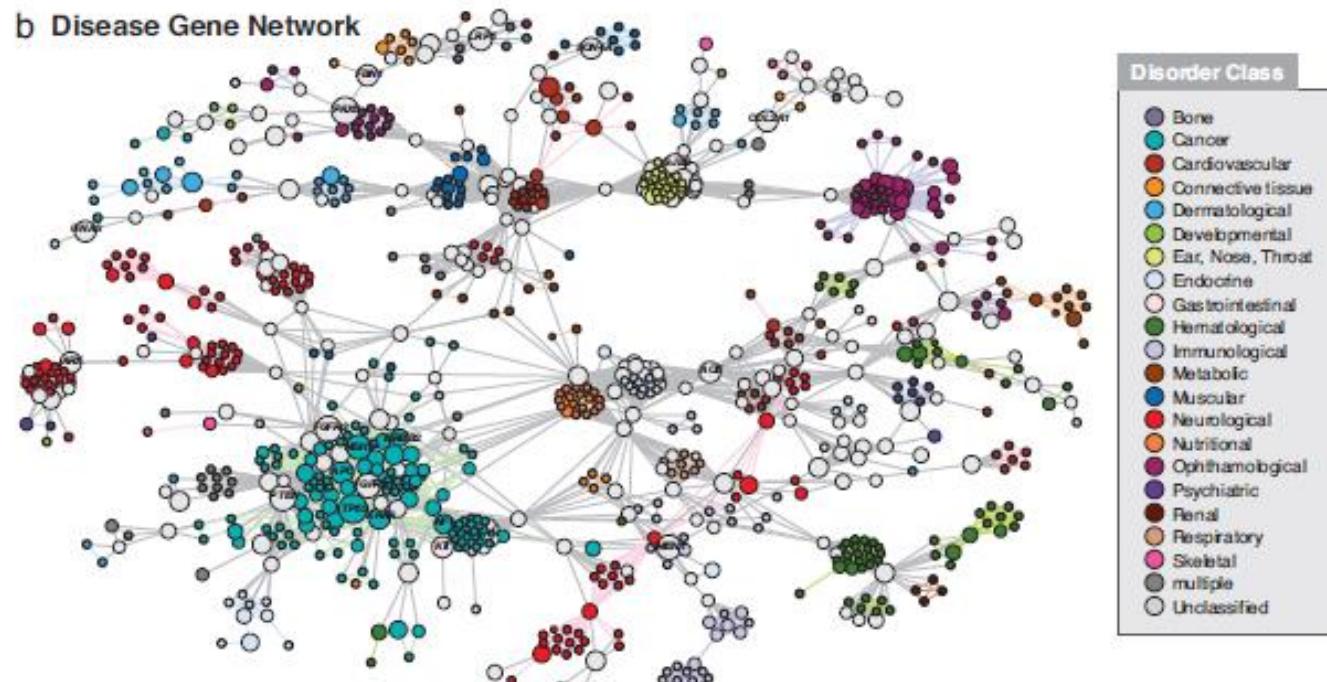


疾患遺伝子 ネットワーク (DGN)

Nodeの径

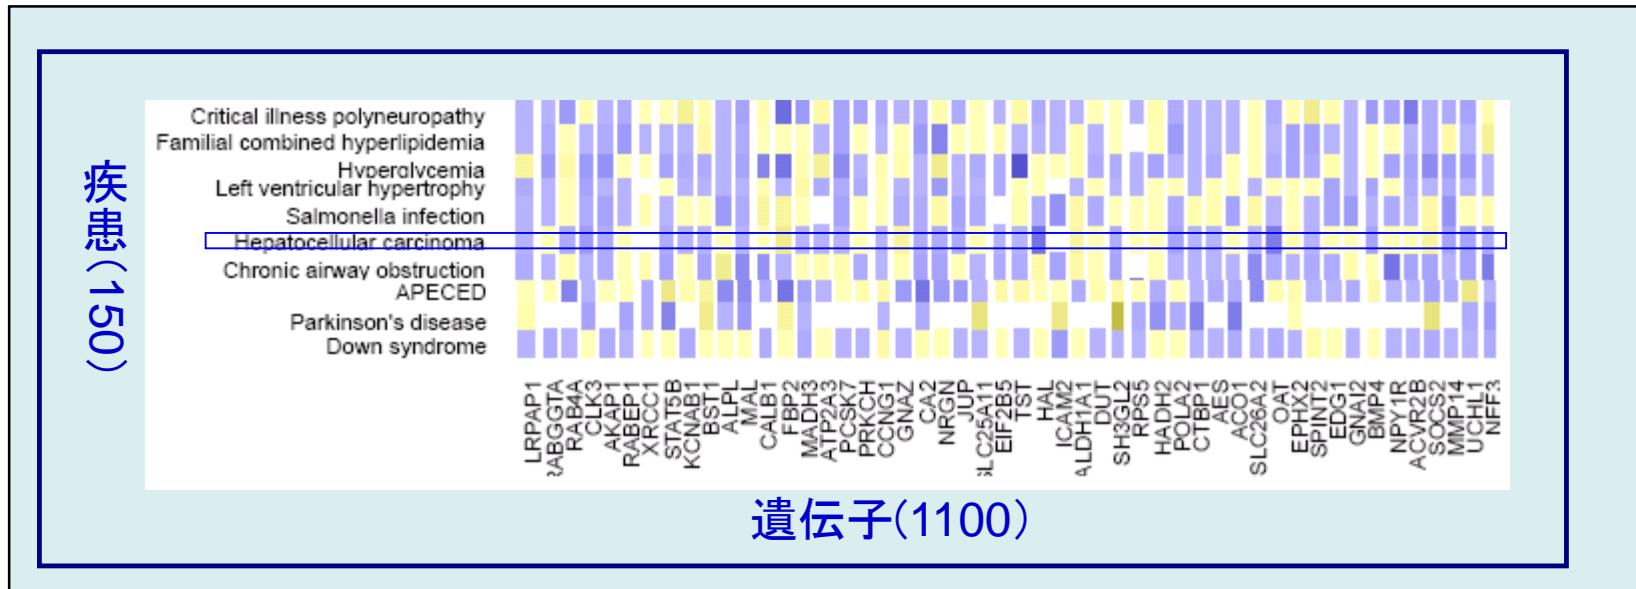
その遺伝子を原因にして
いる疾患の数に比例

2つ以上の疾患に関与して
いると明灰色の遺伝子
ノード



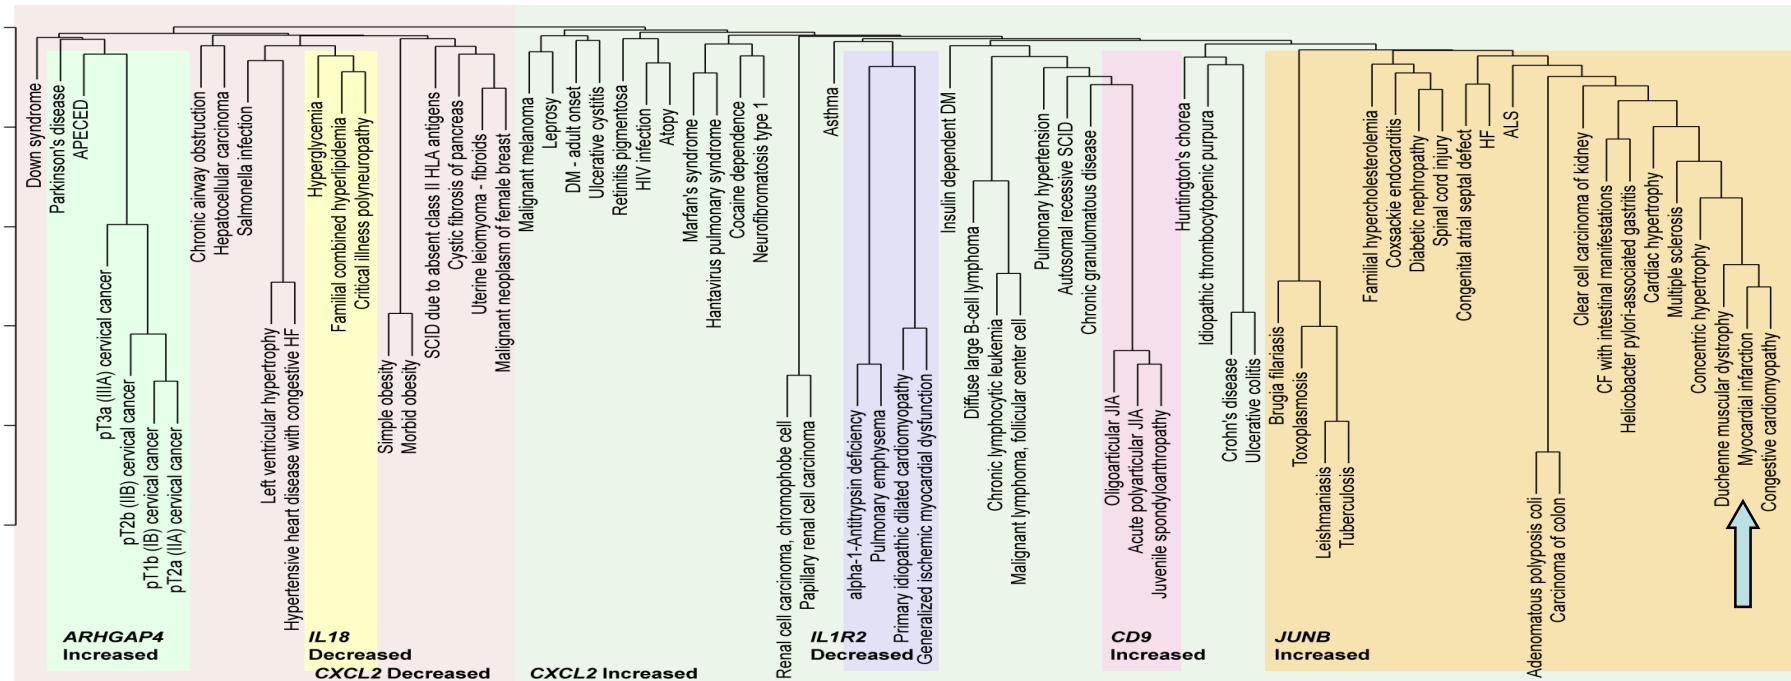
第2世代型 GENOMED (A.Butte et al)

- 遺伝子発現DBのGEO (Gene Expression Omnibus) 利用
 - 約20万のサンプル
- 疾患名は注釈文より用語集UMLSを用いて抽出
- 疾患ごとに多数の遺伝子発現パターンを平均化



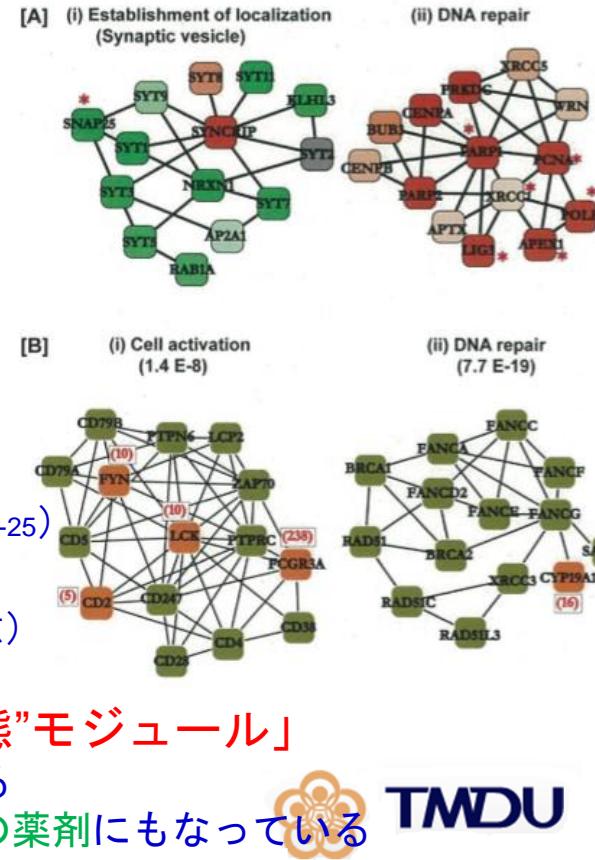
Gene-Expression Nosology of Medicine

- 疾患を平均遺伝子発現パターンよりクラスター分類
 - 臓器別疾患分類では予想できない疾患間の親近性
 - 分類項目はサイトカインの遺伝子発現と相関
 - 疾患の再体系化に基づいた医薬の repositioning
- さらに656種類の臨床検査を結合した分析
- 心筋梗塞・デュシャンヌ型筋ジストロフィーが近い



Transcriptomeの変化をPPIに投影した 疾患ネットワーク (Butte)

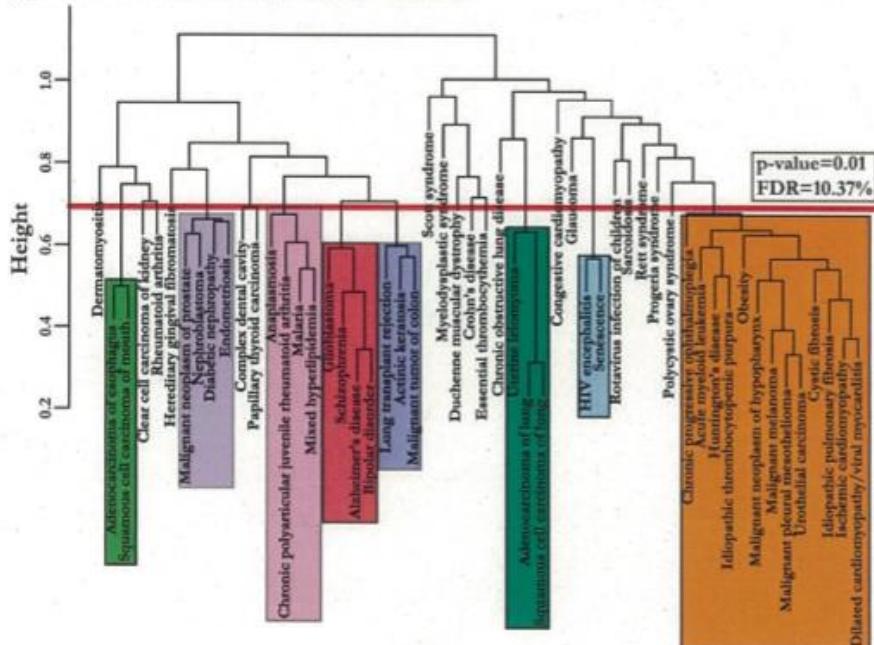
- ネットワークモジュール
遺伝子発現プロファイルではなく4620に分解したタンパク質相互作用
ネットワークの<機能moduleでの疾患時の平均発現変化>とともに疾
患ネットワーク構築
- 基本方法
 - GEOから信頼性などより54の疾患を選択
 - 各疾患について各moduleに含まれる遺伝子群の
疾患時と健常時の発現差のt統計量の平均
 - MRS:** Molecular Response Score
各疾患に各モジュールで定義（ベクトル量）
 - 疾患間の相関は、両疾患の健常時発現を制約とした
 - MRSの偏相関係数
- 疾患ネットワークの性質
 - 138の有意な類似性**：ランダム化ネットに対し有意
 - p<0.01, FDR=0.1
 - 疾患類似性**: 肺がん群(修復pasM), 精神疾患(synapsM:SNAP-25)
- 138の有意な疾患相関**
 - 17は少なくとも1つの共通薬：14疾患は共通の薬剤に有意
 - Flourarcil（日光性角化）⇒大腸がん、ほかDoxorubicin
- 疾患の大半を占める59モジュール：「共通“疾患状態”モジュール」
 - 「共通疾患状態シグネチャ」薬剤標的分子に富んでいる
 - この遺伝子群を標的にする薬剤は有意に多くの他の疾患の薬剤にもなっている



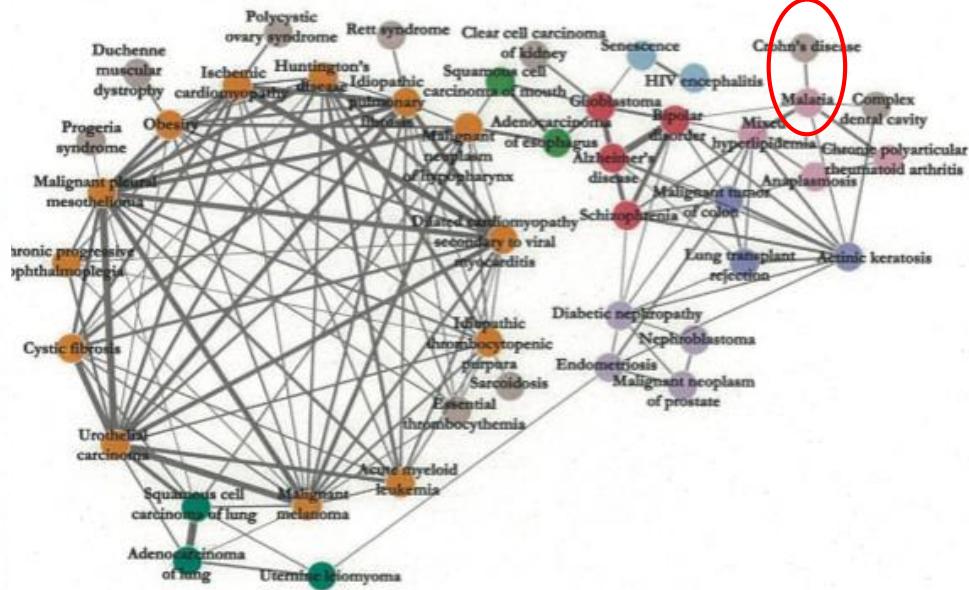
Transcriptomeの変化をPPIに投影した 疾患ネットワーク (Butte)

- アルツハイマー症、統合失調症、双極性障害がグループ化
- 子宮筋腫と肺がん、マラリアとクローン病
- 17のがんが1つの群ではない。がんの異質性
- 疾患ネットワーク間の遺伝子共有は高くない（遺伝子外効果）

[A] Hierarchical relationships between diseases



[B] All significant disease correlations



階層的クラスタリング

疾患ネットワーク



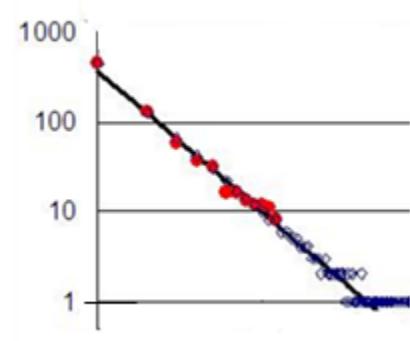
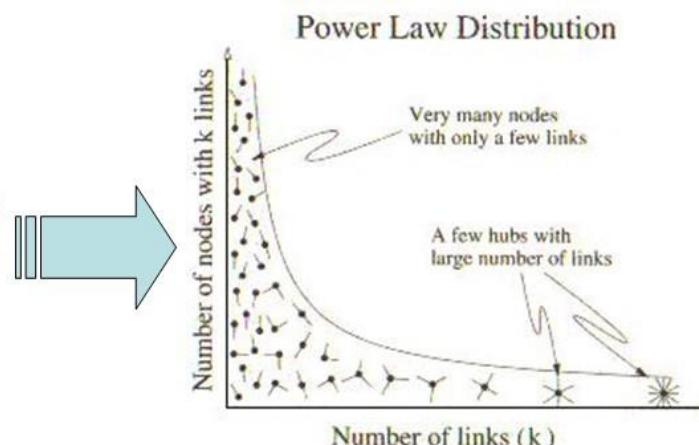
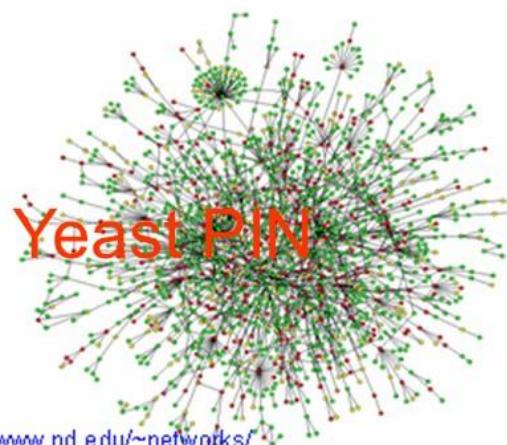
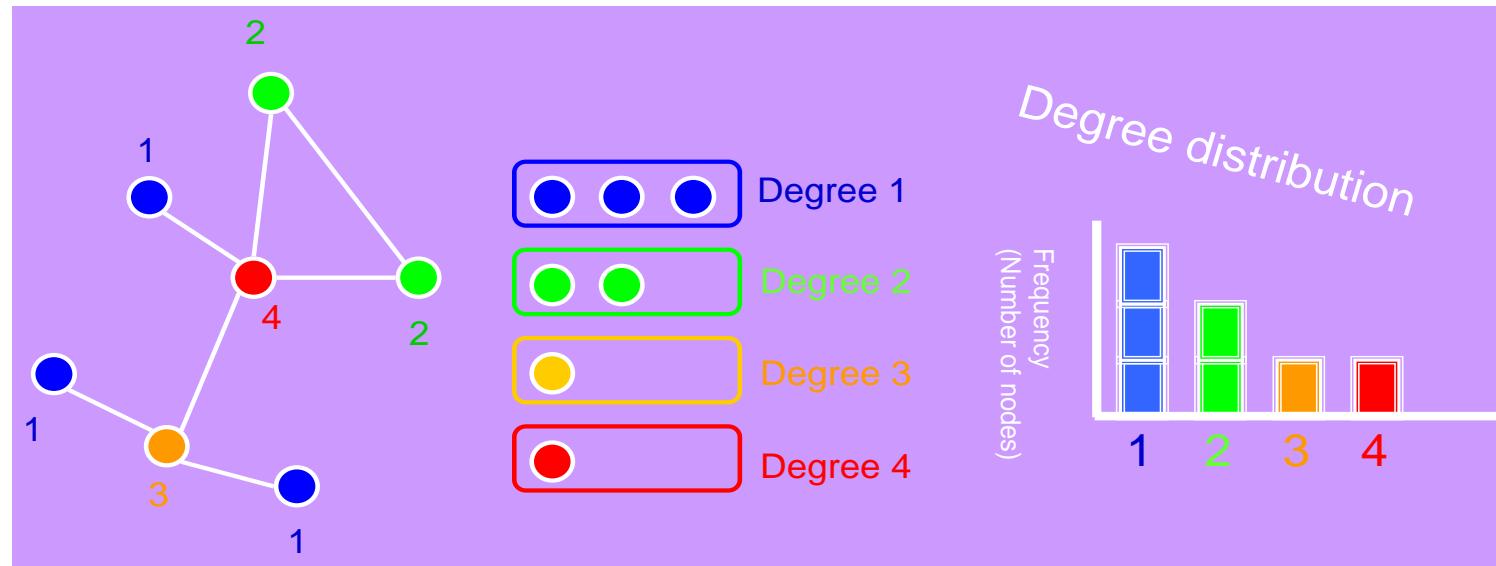
TMDU

3. Interactome 創薬/DR

Protein間相互作用ネットワーク(PPIN) を
基礎にした創薬/DR

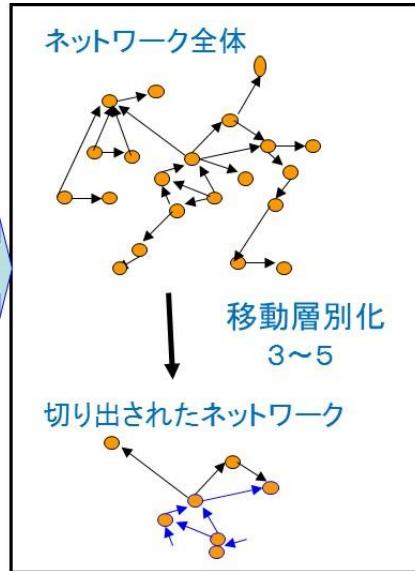
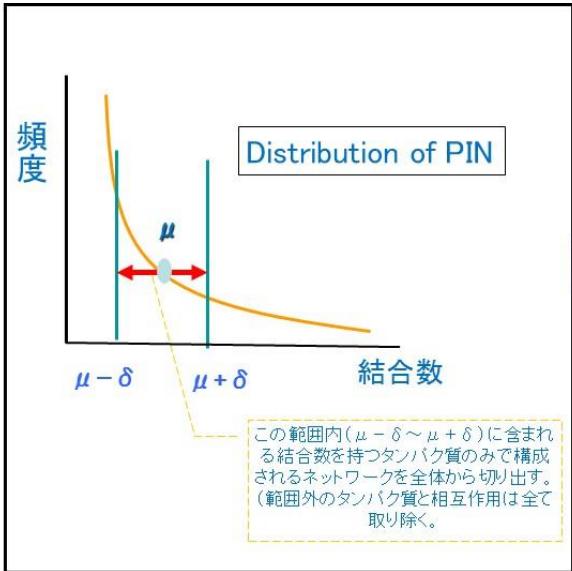
＜薬剤標的分子と疾患遺伝子のPPINでの距離＞

タンパク質相互作用ネットワーク(PIN)では数少ない相互作用が集中したタンパク質(hub)と相互作用が1や2の多数の末端タンパク質(branch)が存在する

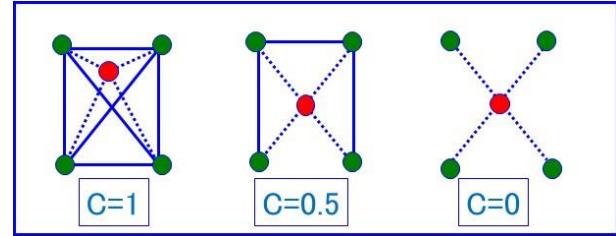


Log-log変換で直線

結合次数ごとの部分ネットワーク構造の結合密度の解析

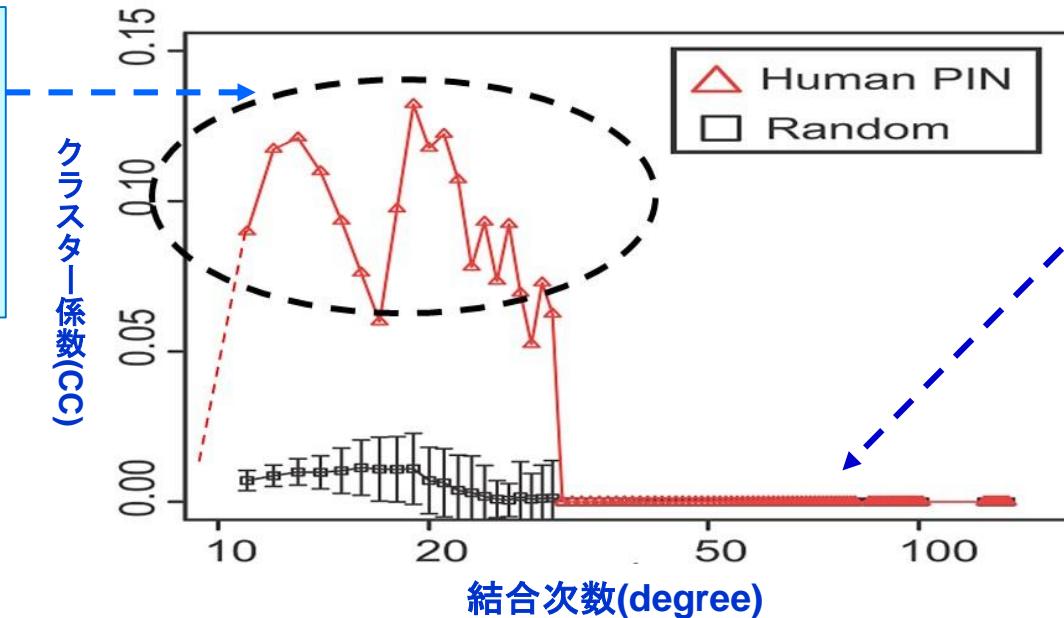


クラスター係数



Hase, T., Tanaka, H et.al (2009)
Structures of protein protein interaction network and their implications on drug design. *PLoS Comp Biol.* 5(10):

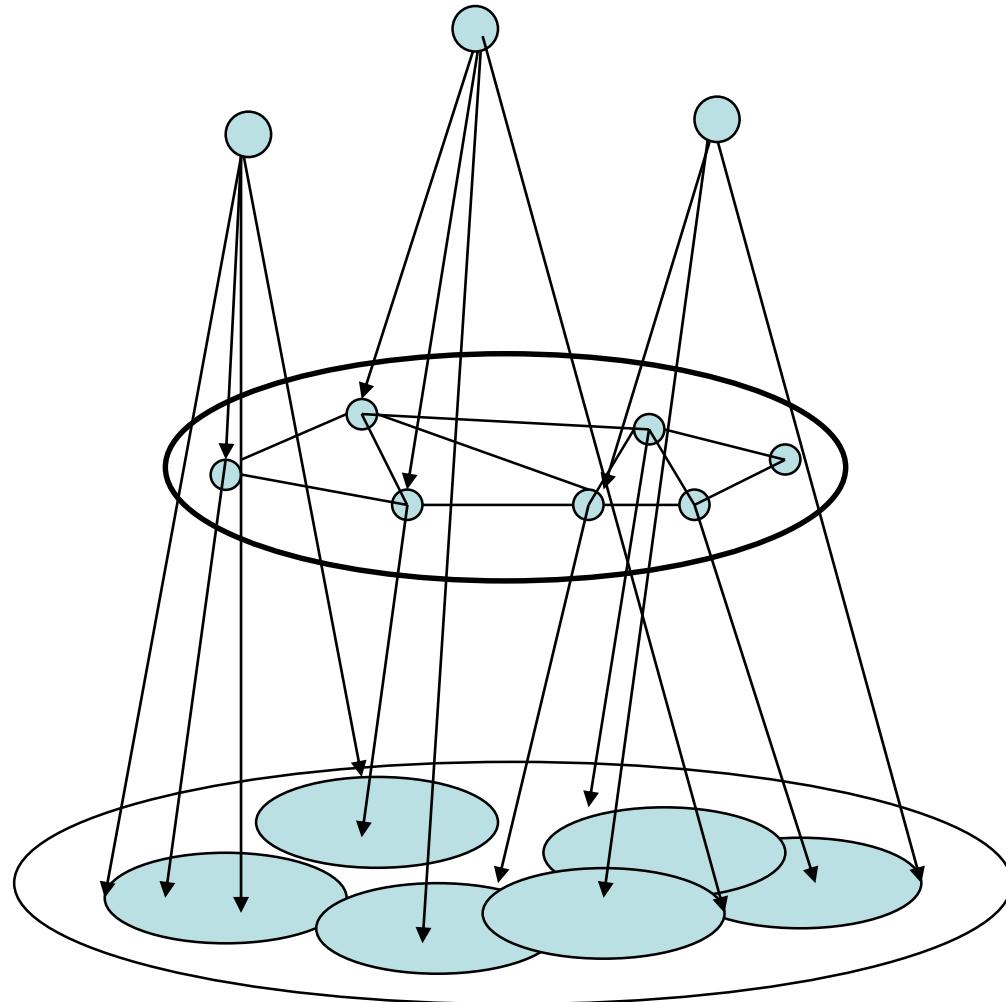
中程度の結合数(7~42)を持つタンパク質は多数の密なモジュールを構成



高い結合次数を持つノード(スーパー・ハブ)はお互いに密に結合しない

タンパク質相互作用から見られる

生命情報ネットワークの構造



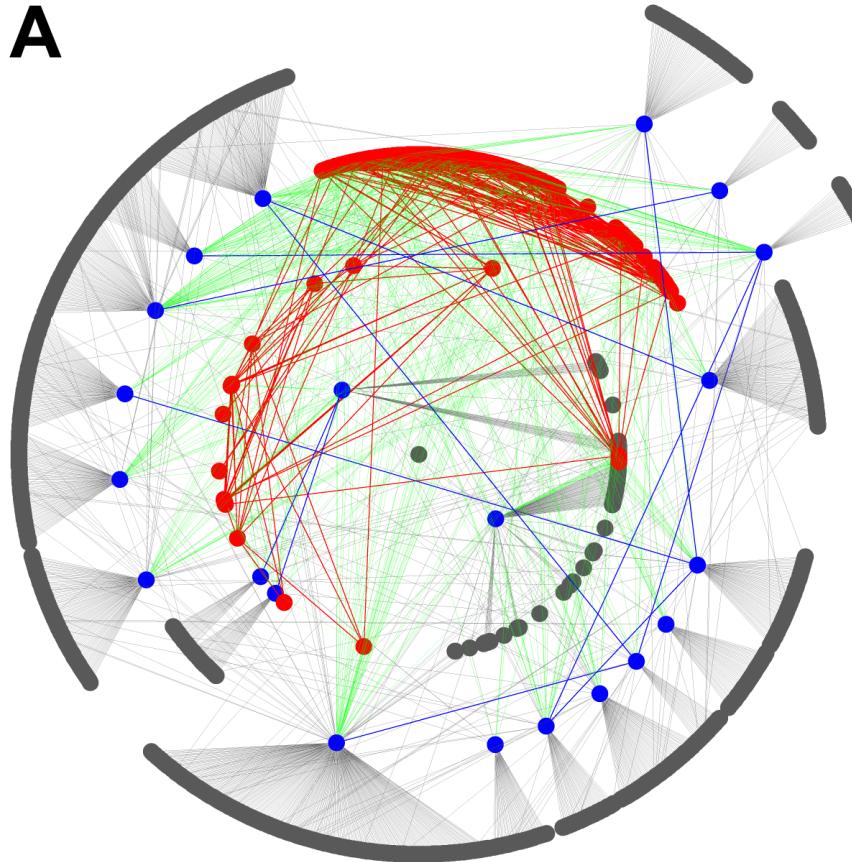
高次層
高結合数分子
ハブ分子
度数 > 31 ヒト
> 39 酵母

中間層
中結合数分子
バックボーン分子
度数 6 ~ 30 ヒト
6 ~ 38 酵母

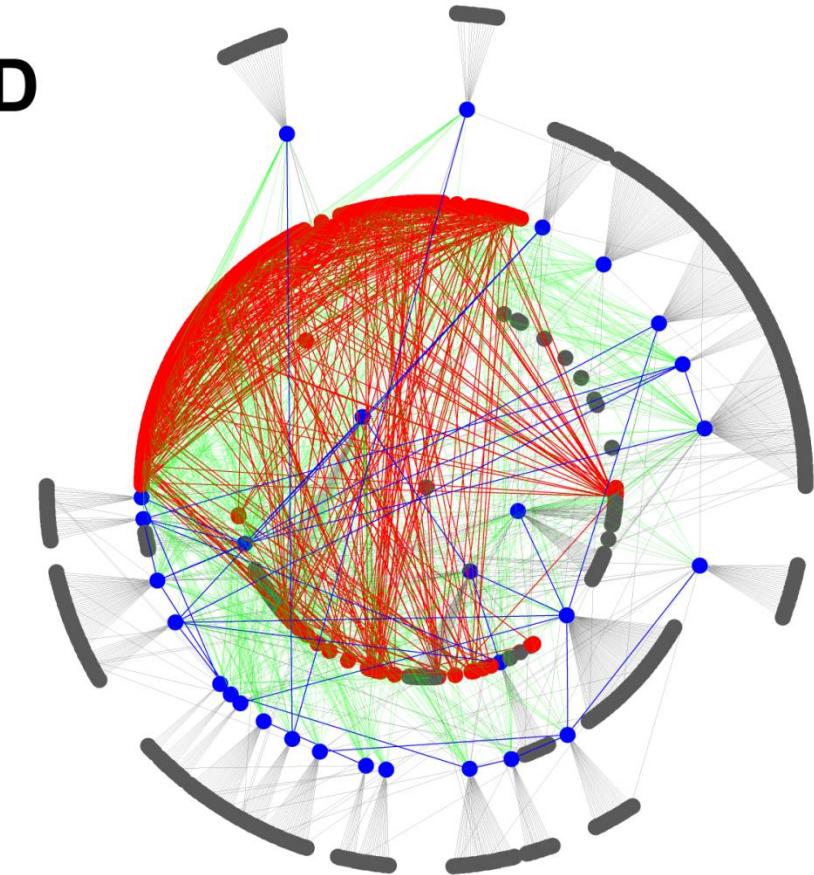
低次層
低結合数分子
ブランチ分子
度数 < 6

InteractomeのCloud Topology (3環トポロジー)

Yeast



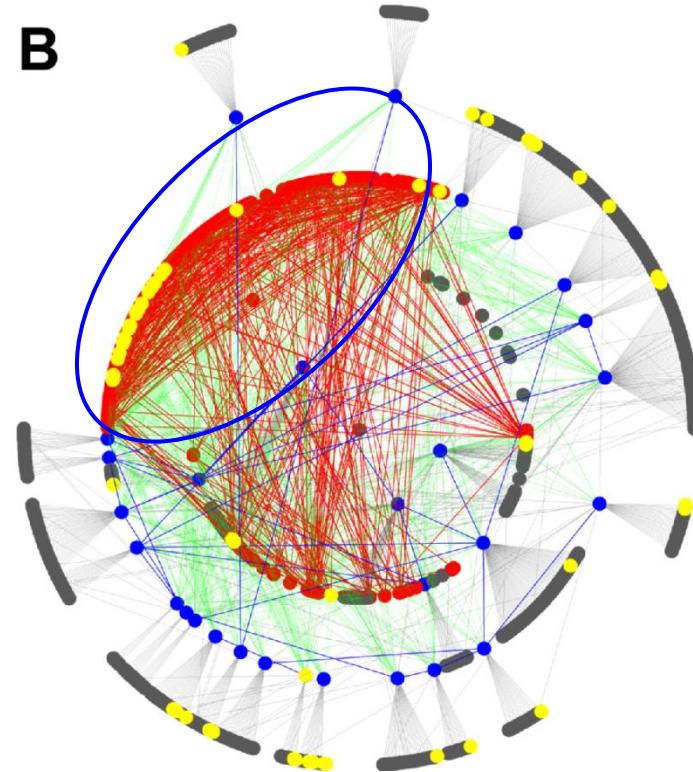
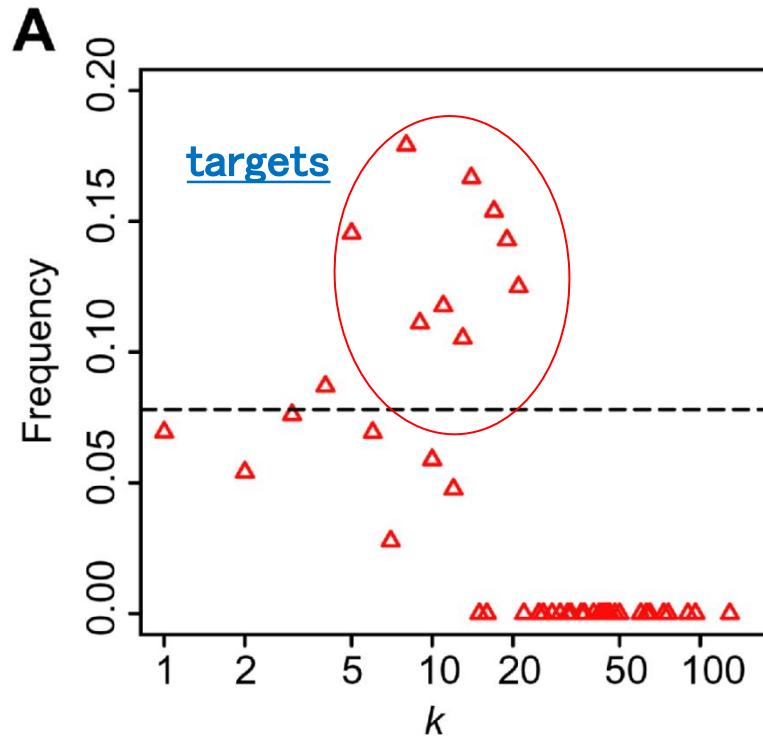
Human



Middle-degree ノードは PPI backbone を形成する。

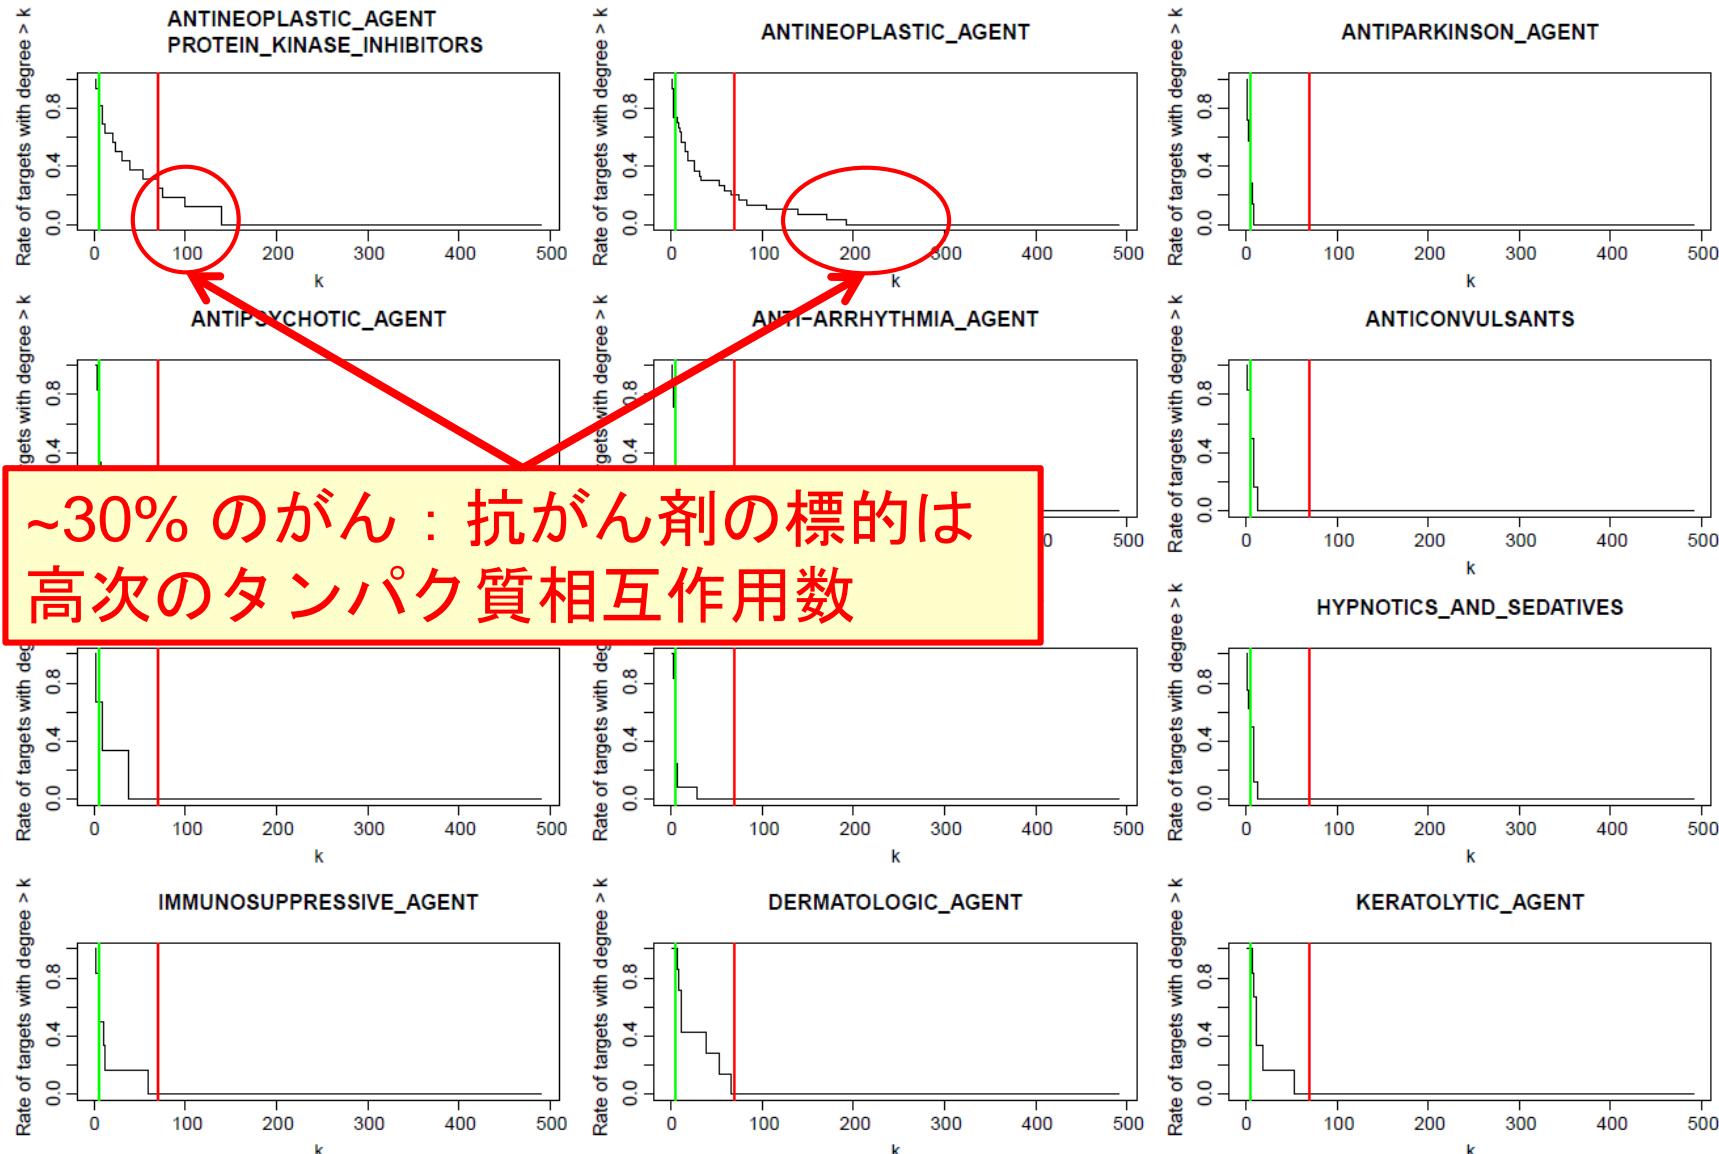
灰色, 赤, 青は、それぞれ低層、中層、高層のdegreeのノードをそれぞれ表す。

薬剤標的分子と結合度数



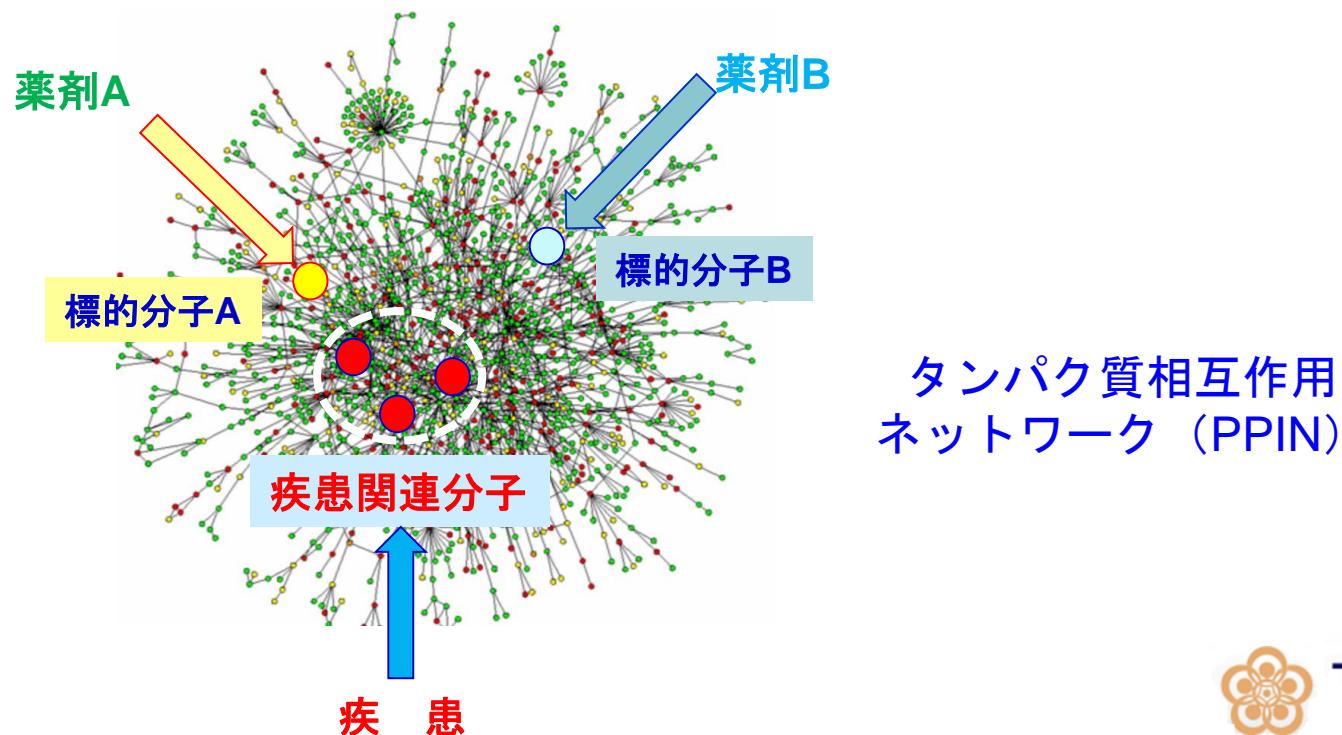
中層レベルのノードは治療薬として最適な標的である。それゆえ、多くの市場にある薬剤標的是、ヒトのバックボーンタンパク質に集中している

がんの疾患遺伝子は高次結合ハブのタンパク質が多い



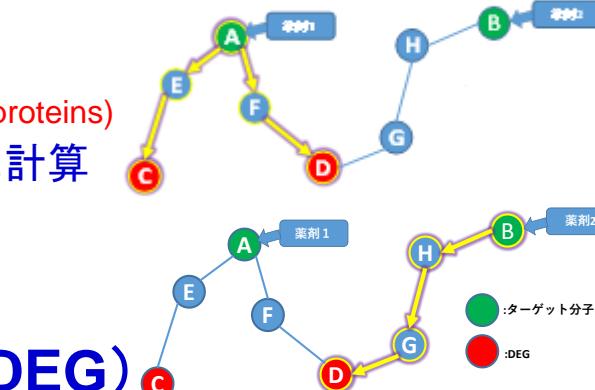
標的分子や疾患要因分子の タンパク質相互作用ネットワーク (PPIN)

- ・ 薬剤ネットワークと疾患ネットワークを媒介する第3の生体ネットワーク
- ・ タンパク質相互作用ネットワーク (PPIN) での創薬/DR戦略
- ・ PPIネットワーク場を基礎にして距離 (類似性) を検討
- ・ 薬 剤 : 薬剤の標的分子 (タンパク質) によって PPI場と繋がる
- ・ 疾 患 : 疾患特異的発現遺伝子を疾患要因分子 (タンパク質) へ翻訳、
- ・ PPIN場内での薬剤標的分子と疾患の「代理人(疾患遺伝子)」の距離・親近性を基準に、薬理作用のインパクト力を評価



PPIの基づくDR（肺腺癌の例）

- **Interactome(タンパク質相互作用)ネットワーク (Sun, 2016)**
 - HPRD (Human Protein Reference Database)
 - 37,070 PPI, 9465 タンパク質
 - STRING (Search Tool for the Retrieval of INteracting Genes/proteins)
 - 184 M PPI, 9,643,763タンパク質 --- 個々に計算
- **薬剤→標的分子 : DrugBank**
 - 7,759 薬剤、4300タンパク質
 - 12,604 薬剤一標的分子 (4,452薬剤, 1,617タンパク質)
- **疾患遺伝子の差異的遺伝子発現データ (DEG)**
 - TCGA (The Cancer Genome Atlas) より差異的発現遺伝子を同定
 - 445 肺腺癌例, 19 正常例, 疾患遺伝子 FC >2.0 or <0.5, FDR<0.01, 927 差異的発現遺伝子
- **薬剤の疾患遺伝子への影響力 評価IPS (Impact power score)**
 - 薬剤の標的分子と疾患遺伝子の間のネットワーク距離の総合評価
「再出発ありランダム歩行RWR」でネットワーク距離を評価
 - 標的分子からランダム歩行を繰り返す (出発点から再出発あり)
s時点後, 疾患遺伝子のノードにどれだけの確率で滞在しているかをIPSとする
 - 一定の時間が過ぎると、定常状態になり、歩行で滞在確率分布は変化しない。
定常状態での疾患遺伝子ノードに滞在している確率の総和が薬剤の評価になる



$$\mathbf{P}^{s+1} = (1 - \gamma) \mathbf{M} \mathbf{P}^s + \gamma \mathbf{P}^0$$

\mathbf{P}^s : 時点sでの各ノードでの滞在確率

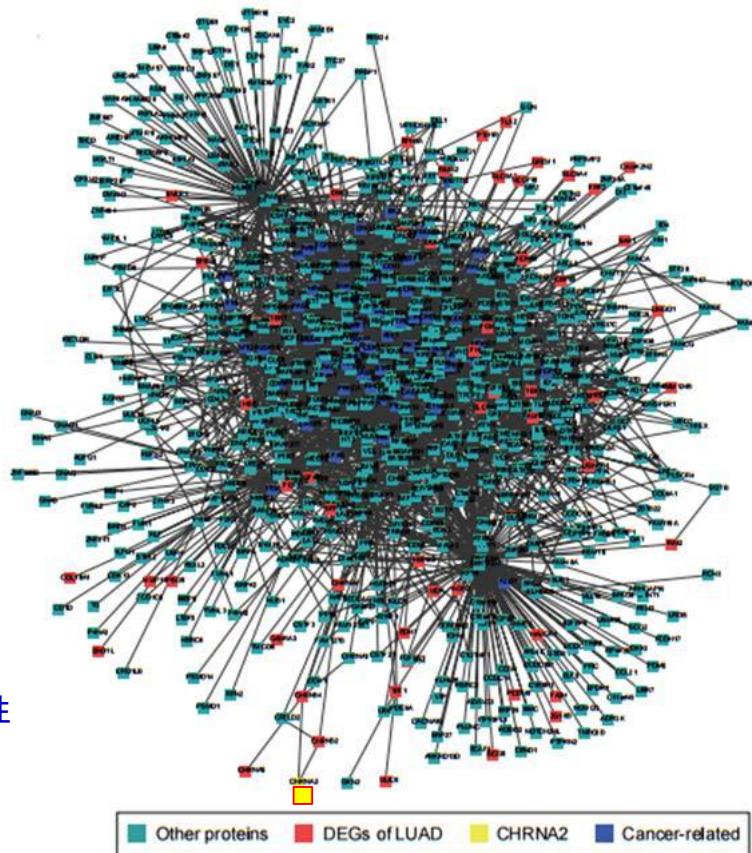
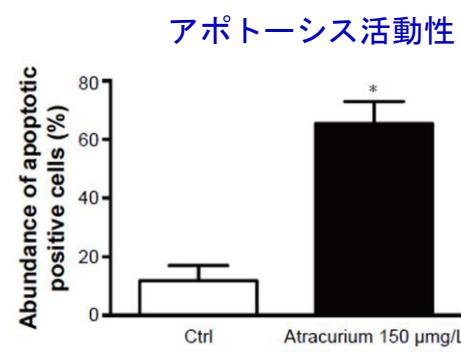
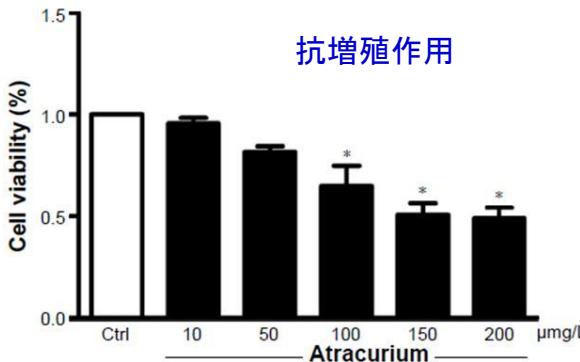
\mathbf{M} : 各ノードへの遷移確率

γ : 再出発確率

Interactome DR 結果の検証

Drug ID	Drug name	Target	Score	Rank
DB00416	Metocurine Iodide	CHRNA2	0.966581	1
DB00565	Cisatracurium besylate	CHRNA2	0.966581	1
DB00732	Atracurium	CHRNA2	0.966581	1
DB00657	Mecamylamine	CHRNA2	0.966581	1
DB02457	Undecyl-phosphinic acid butyl ester	LIPF	0.953846	5

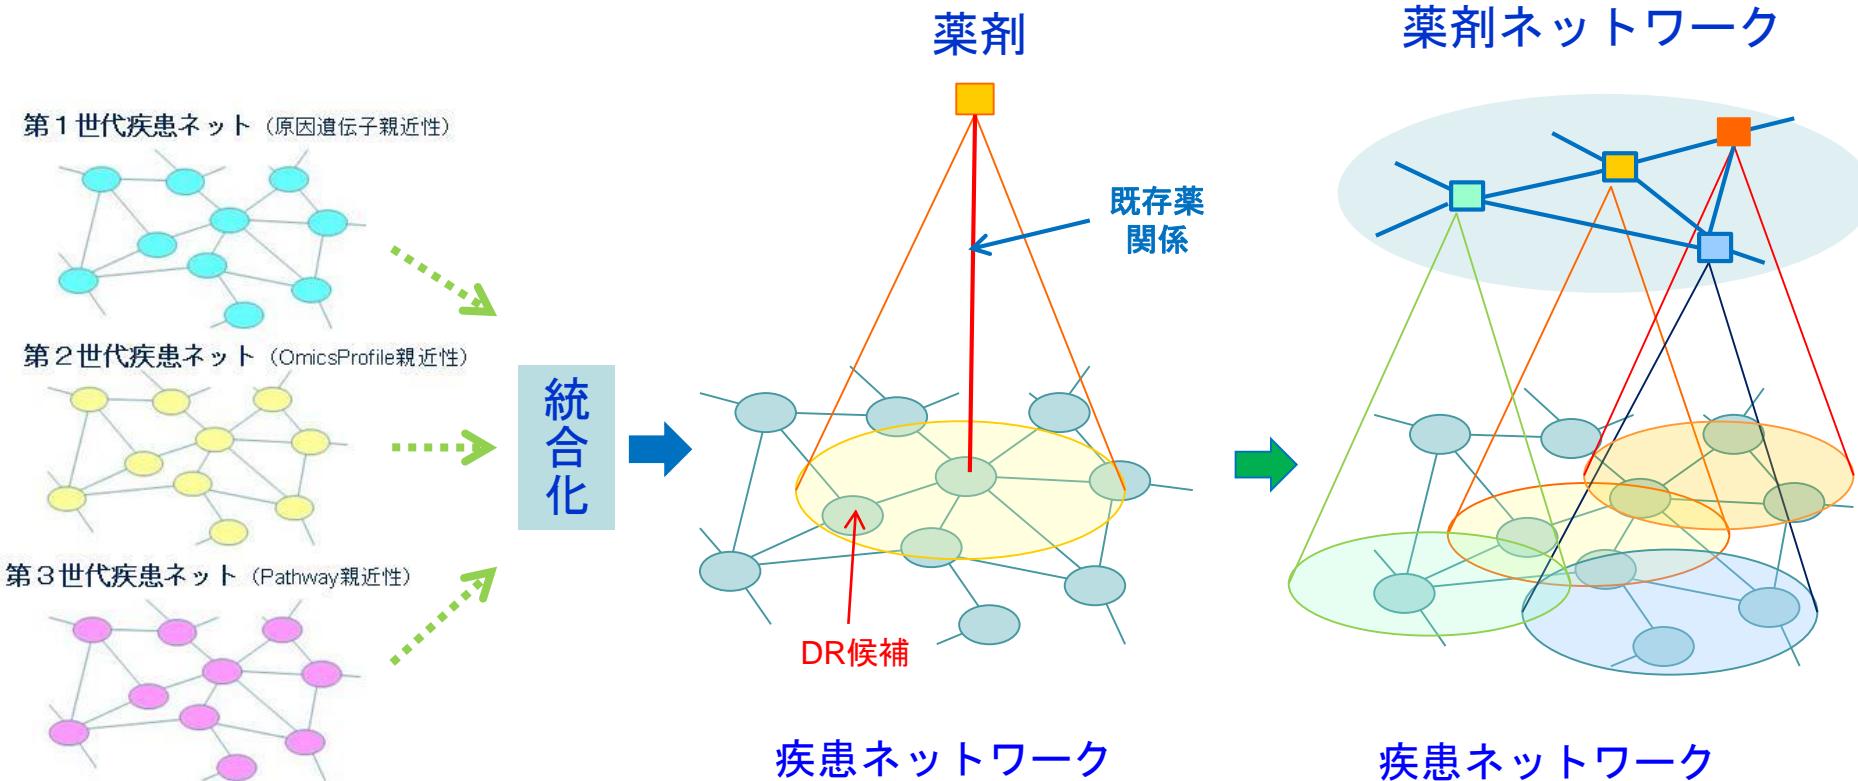
- HPRDとSTRINGの両方のPPINのランダム歩行でtop5%で共通な**145薬剤**を同定
- 最高スコアを挙げた**Atractium**を選択
- 薬剤標的は**CHRNA2**(Cholinergic Receptor Nicotinic Alpha 2) で**アポトーシス経路**である
- 培養細胞**A549**（ヒト肺胞基底上皮腺癌）の抗増殖作用を確認



＜疾患-薬剤-標的分子＞の 多階層ネットワークによる ビッグデータ創薬/DR

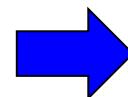
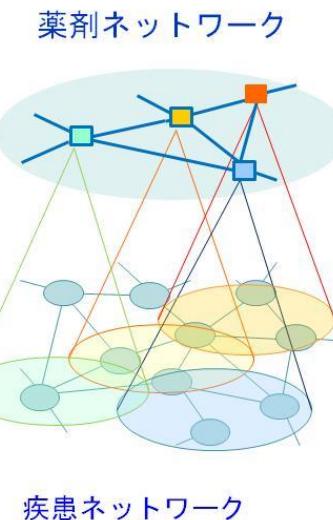
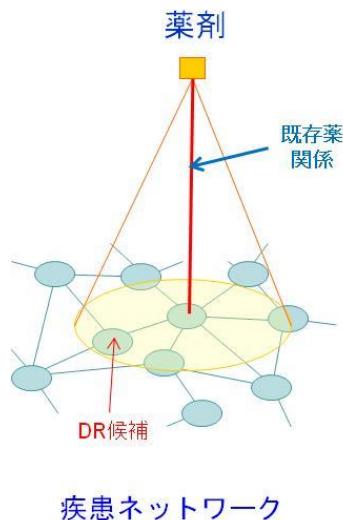
疾患ネットワークとDrug Projection Map

薬剤/疾患ネットワークの構築

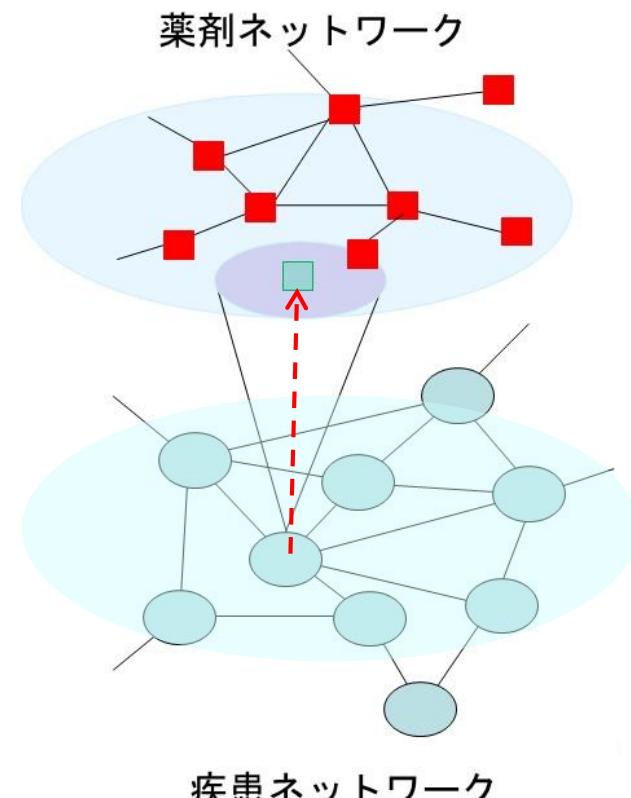


DRの方法論から創薬方法論へ

- 疾患ネットワークの十全な形成
 - 内在的機序の近親性から疾患ネットワーク
 - 医薬品の有効性・毒性の近傍 Projection
→ DRにおける**有効性**はすでに確立
- 創薬への展開
 - 薬剤階層のネットワークは既に確立
 - 投与時生体反応の近親性だけではなく
 - 化合物の構造的近親性(finger print)からも作成
 - 疾患から逆投影。創薬の可能性探索
- 疾患ネットワークと薬剤ネットワーク間写像
 - 双方向性・対等性



疾患から薬剤ネットワークへの逆投影
Multi-Topology 双対写像 創薬方法論

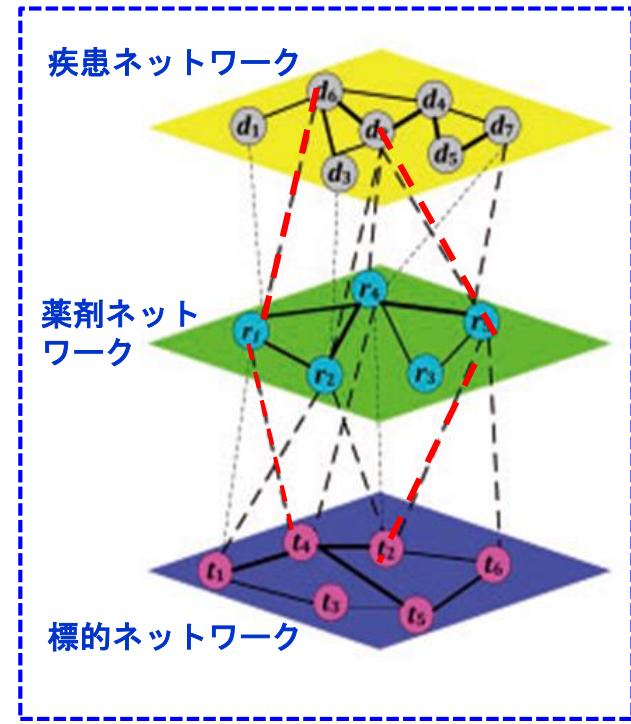


3階層生命ネットワークでの創薬/DR

- 3階層の生体ネットワーク
 - 疾患ネットワーク：網羅的分子による内在的機序
 - 薬剤ネットワーク：化学構造によってネットワーク
 - 標的ネットワーク：薬剤と標的（DrugBank参照）
- 各層のネットワーク内結合
 - 稠密に自己完結的に構築可能
- 各層ネットワーク間のリンク
 - 成功した<疾患－薬剤>の事実の根拠のみ
 - 階層間はスパースな結合である

創薬/DRとは

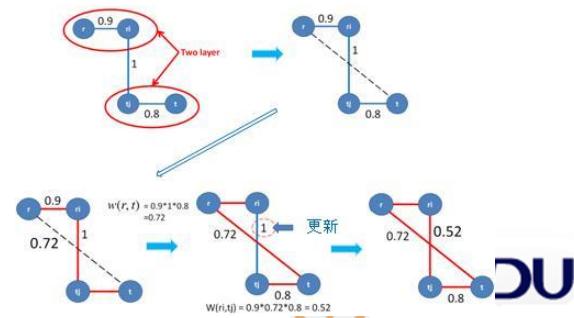
未発見の階層間リンクを
既存の階層間リンクの事実と
各層のネットワークから推測



(Wang et al. 2014)

Wang et al. 2014は

- 階層間リンク（事実）と各階層内のリンクより階層間のリンクの強さを計算する方法を提案している



Wangの異質ネットワークの計算アルゴリズム

• 3層ネットワーク構成

- 疾患-疾患 (d_i), 薬剤-薬剤(r_j), 標的-標的 (t_i)
- 疾患-薬剤間の距離を2階層のレベル内での距離から計算

• 各ネットワークで距離定義

- 疾患 : 表現型⇒MeSHの共通項数
- 薬剤 : 化学構造⇒Tanimotoスコア
- 標的 : Protein配列類似性⇒Smith-Waterman法
- 疾患-薬剤 : 過去研究、薬剤-標的ネット : Drugbankより
- 失われた疾患-病気 Edge復元

• 結合係数 $W(i,j)$ 更新法

$$w(d, r) = \sum_{d_i \in D} \sum_{r_j \in R} w(d, d_i) \times w(d_i, r_j) \times w(r, r_j)$$

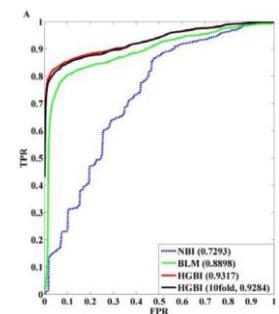
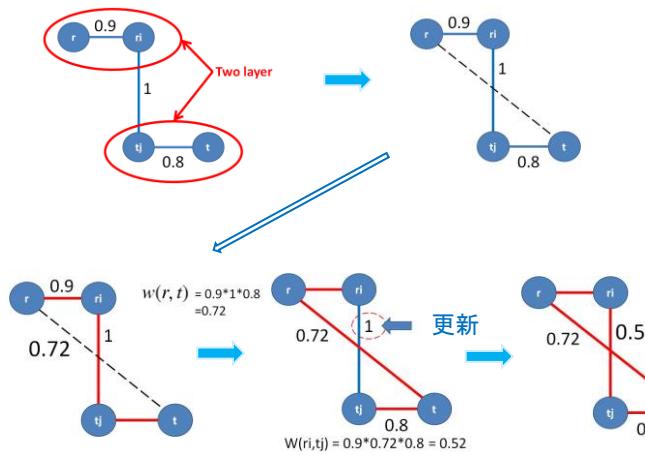
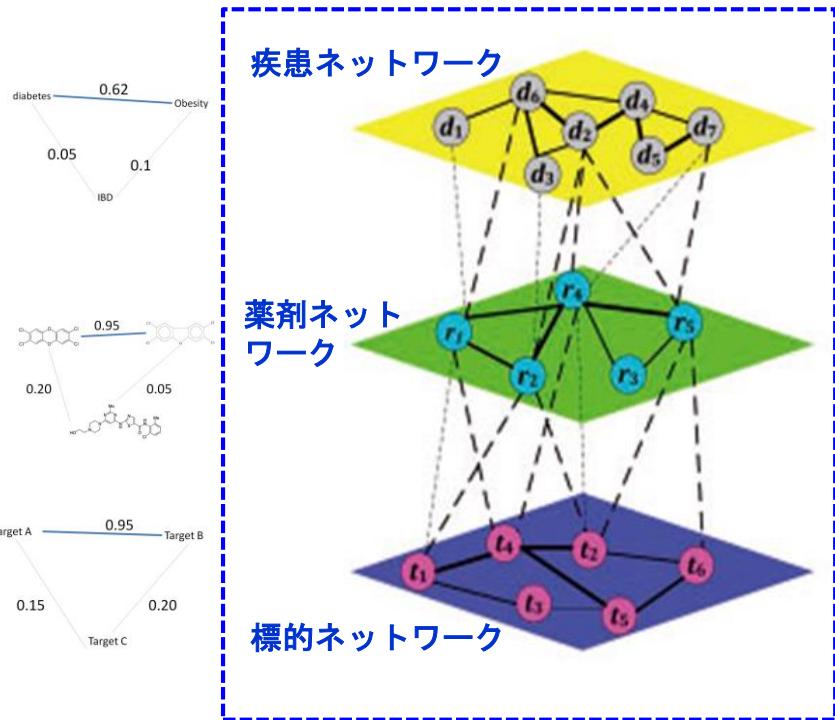
$$w(d, t) = \sum_{r_i \in R} \sum_{t_j \in T} w(d, r_i) \times w(r_i, t_j) \times w(t_j, t)$$

$$w(d, r) = \sum_{t_i \in T} \sum_{r_j \in R} w(d, t_i) \times w(t_i, r_j) \times w(r_j, r)$$

結合係数更新のマトリックス表示

$$W_{dr}^{k+1} = \alpha W_{dr}^k \times (W_{rr} \times W_{rt}^k \times W_{tt} \times W_{rt}^{kT}) + (1 - \alpha) W_{dr}^0$$

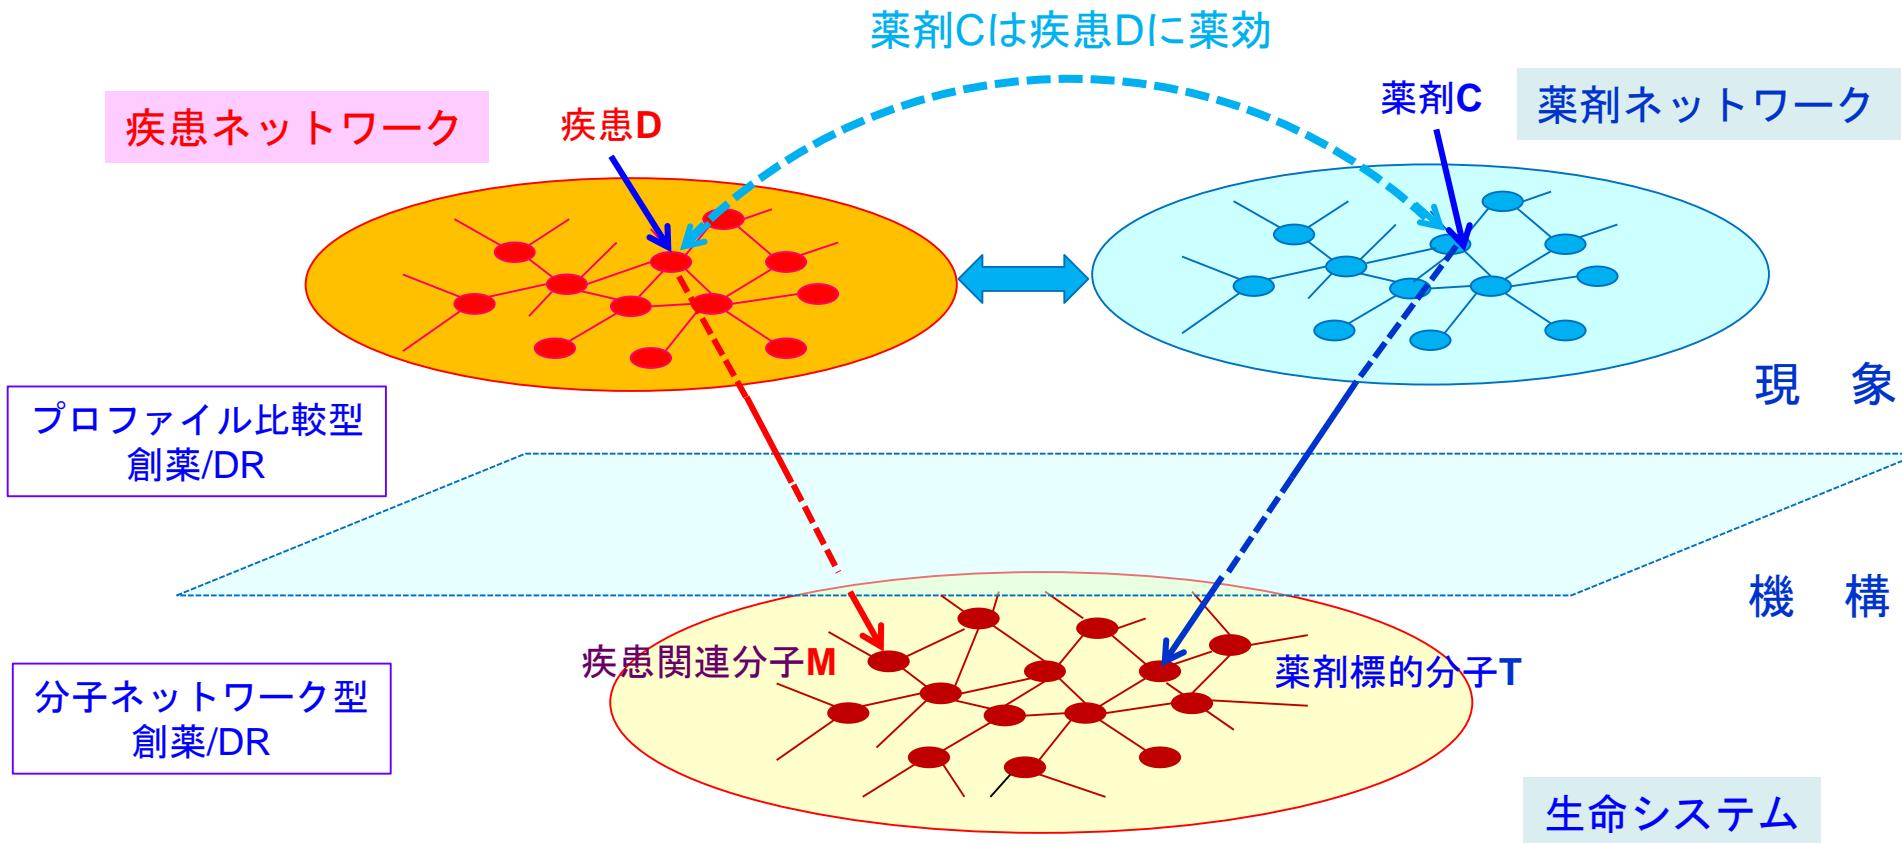
$$W_{rt}^{k+1} = \alpha (W_{dr}^{kT} \times W_{dd} \times W_{dr}^k \times W_{rr}) \times W_{rt}^k + (1 - \alpha) W_{rt}^0$$



従来の方法より
DR推定精度高い
ROC曲線

プロファイル型計算創薬の原理

3層生体・薬剤ネットワークのFramework

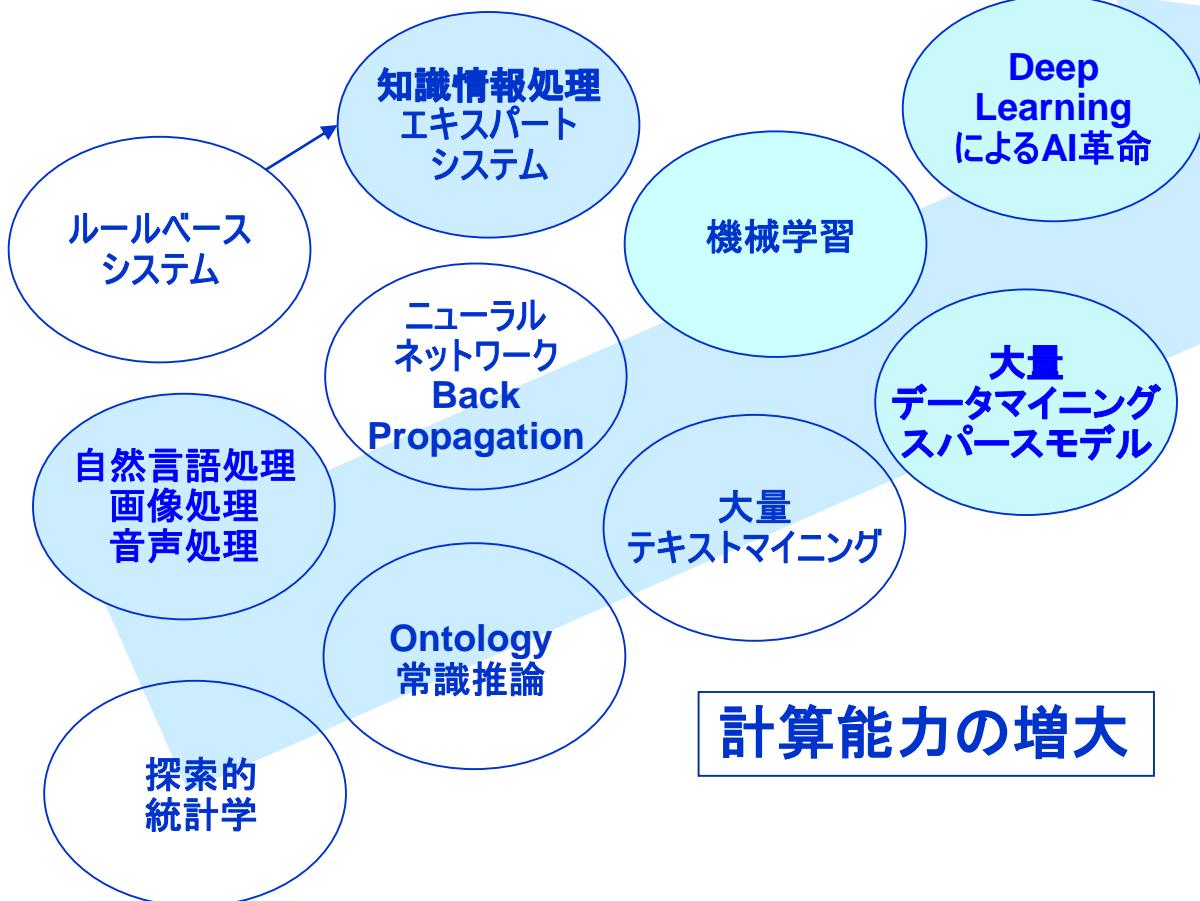


第2部

人工知能（AI）創薬・DR

人工知能への期待

人工知能（AI）の分野



ビッグデータ
人工知能による
知的処理

計算能力の増大

医療分野の人工知能の歴史

記号（シンボル）的知識処理

問題解決の一般探索手法 GPS
解決木の高速探索（ゲーム）

推論システム（if-thenルールシステム）
知識の表現と利用（専門家システム）
医療診断システム（Mycin, Internist-I）
大ブーム 医療から産業応用の期待波及

期待消滅！

知識発見 機械学習
Machine Learning, KDD
診断知識のDBからの学習

知識準拠診療支援（DSS）
医療ターミノロジー
医療オントロジー

ニューロネットワーク処理

ニューロネットワーク
3層の学習機械 Perceptron
入力層、隠れ層、出力層

多層型ニューロネット
後方伝播 Back Propagation
結合係数修正アルゴリズム

しばらく停滞！

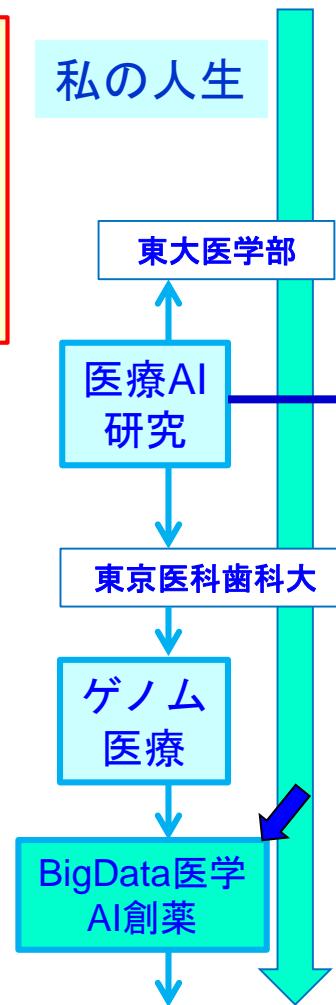
ニューロネットワーク型
多層型ニューロネット
深層学習 Deep Learning
結合係数修正アルゴリズム
画像処理から創薬まで

自己紹介と医療人工知能の歴史

人工知能(AI)を医療・創薬へ応用

田中 博
東京医科歯科大学
生命医療情報学
東北大学
東北メディカル・
メガバンク機構

1980から1995
第1期の
AIブームの時
医療AI研究に従事



記号知識処理

問題解決の
探索法 (GPS)

医学「知識」を
計算機に格納
医療診断システム (MYCIN)
知識工学：大ブーム
政府：第5世代コンピュータ
知識の移植問題

ブーム消滅！

医療機械学習
診断知識のDBからの学習

診療支援
医学の用語や
概念体系の基礎理論

ニューロネット(NN)

単純NN
パーセプトロン
判別能力の限界

1970
以前

1980

多層NN
バックプロ
パゲーション
重み修正の限界

1990

ブーム消滅！

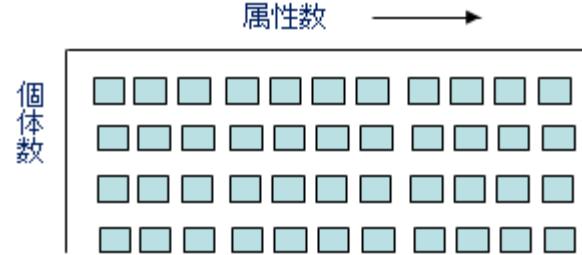
2000

Deep Learning
多層NN
「教師なし」特徴学習

「ビッグデータ」のData 原理

問題点 属性値数(p)»サンプル数(n)

p : 数億になる場合あり n : 多くても数万、通常数千



これら膨大な属性変数がすべて独立ならばビッグデータの構造解析は不可能。单变量解析の羅列 (GWASのManhattan Plot)しか可能でない



ビッグデータ・スペース仮説

ビッグデータは、多数であるが属性値数より少ない独立成分が基底となって、相互にModificationして構成されている。
(独立成分の推定は、サンプル数とともに増加する)

データ次元縮約の原理 (principle of compositionality)

ビッグデータ解析に向けた 2つの人工知能（AI）方法の適用

- **数理的知識処理**：データマイニング、探索統計学の数理的枠内で次元縮約
 - ⇒ スパース推定による従来手法の次元落ちの正則化
- **ニューロネットワーク**：Deep Learningによる特徴量抽出を用いた次元縮約
 - ⇒ Deep LearningのAutoEncode機能を用いた実質的な独立次元抽出に基づいた解析・予測

数理的知識処理

スパース推定による次元落ちの正則化

従来の重回帰分析

$\mathbf{x} = (x_1, \dots, x_p)$ と目的変数 y に関して n 組のデータ $\{(y_i, \mathbf{x}_i); i = 1, \dots, n\}$

$$y_i = \beta_0 + \sum_{j=1}^p x_{ij}\beta_j + \varepsilon_i, \quad i = 1, 2, \dots, n$$

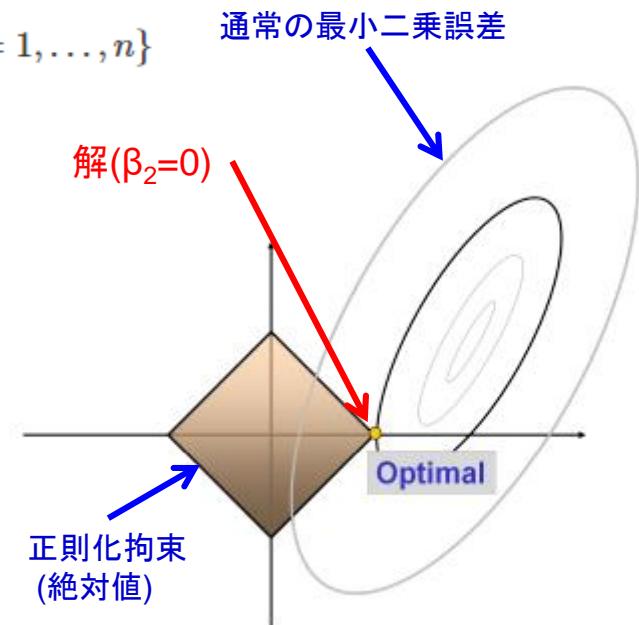
Lasso(L₁型正則化重回帰分析)

$$\hat{\beta}^{\text{lasso}} = \arg \min_{\beta} \sum_{i=1}^n (y_i - \mathbf{x}_i^T \beta)^2, \quad \text{subject to} \quad \sum_{j=1}^p |\beta_j| \leq t.$$

$$\hat{\beta} = \arg \min_{\beta \in \mathbb{R}^p} \frac{1}{n} \|X\beta - Y\|_2^2 + \lambda_n \sum_{j=1}^p |\beta_j|.$$

通常の最小二乗

正則化項 (絶対値)



寄与の低い β_j は0になる ⇒ 変数選択と次元落ち正則化が同時に達成できる

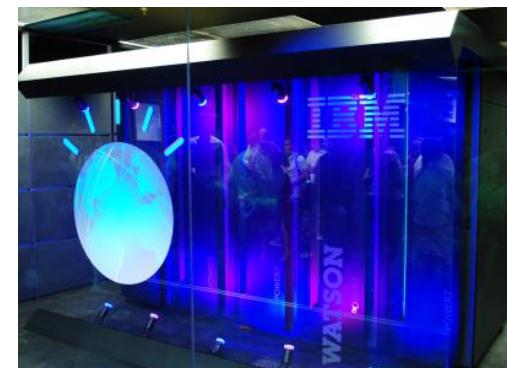
様々な変法 : Larsアルゴリズム(λ を∞から減少), elastic net, adaptive lasso, grouped lasso

様々なスパース正則化の利用

- GWASへの応用
GWASにおけるgene-gene interactionの取り込み
(主効果と相互作用)
 - Correlated SNPs (Ayers and Cordell, 2010)
 - More power while having a lower false-discovery rate (FDR) (He and Lin, 2011)
 - Pathwayに含まれているSNP間だけ相互作用を認める (Lu, Latourelle, 2013)
- 遺伝子発現プロファイルへの応用
 - Biomarker（差異的発現遺伝子）が明確化
- 主成分分析にスパース正則化
 - 主成分の解釈が容易になる
 - 次を最小化
$$Q_\lambda(v_1, X) = \frac{1}{2} \text{trace}[(X - z_1 v_1^T)^T (X - z_1 v_1^T)] + \sum_{j=1}^p p_\lambda(|v_{1j}|),$$
- 判別分析でも正則化により次元縮約

ビッグデータと機械学習

- **The ASCO (米国臨床癌学) CancerLinQ initiative**
 - 診療の現場(EHR)から大量の診療データを集め分析
 - 新しい臨床治験へのガイドライン作成
 - 17万人のがん症例データベースを構築。各がん1～2万人の症例を集める
 - 学習システムを構築し治療知識を統計学習、ニューロネットを駆使して学習。
BigDataにおけるLearning systemの不可欠性
 - 2013年に、CancerLinQのプロトタイプを完成、10万人以上の乳がんを蓄積、完全規模へ継続構築中
- **IBM Watsonのがんセンターへの普及**
 - 質問・応答(QA)システム、知識探索、ライト・オントロジー
 - Memorial Sloan-Kettering Cancer Center (MSKCC)などと共に
 - Watsonを母体に**The Oncology Expert Adviser software (OEA)**開発
 - 他にNew York Genome Centerとglioblastoma(グリア芽細胞腫)知識生成
- **Cancer Commons initiative**
 - Rapid learningのインフラ整備
 - 目的：患者の個別症例と最新の知識を更新
 - 個々の患者の”Donate Your Data”(DYD)登録
- Google X project, “Human Longevity Inc.”

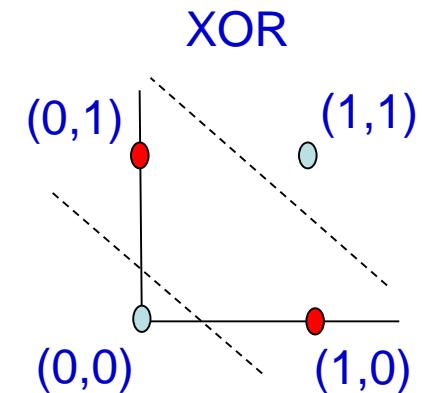
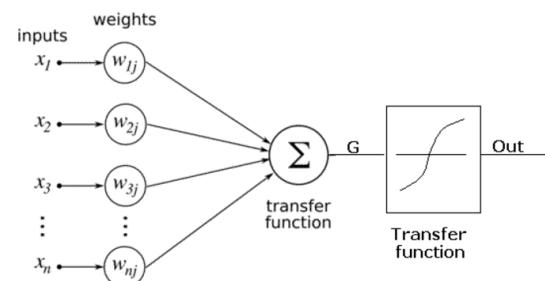
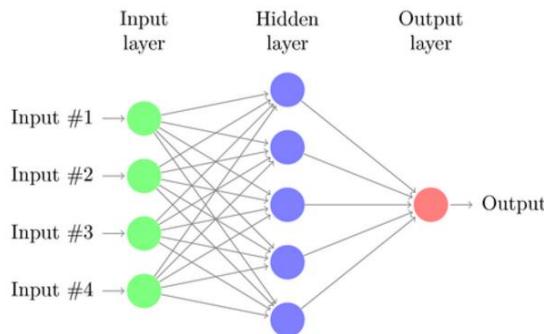


IBM Watson
Learning Big
Data

Deep Learning 型人工知能の 革命性

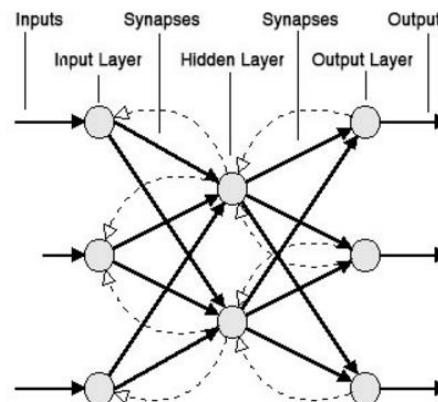
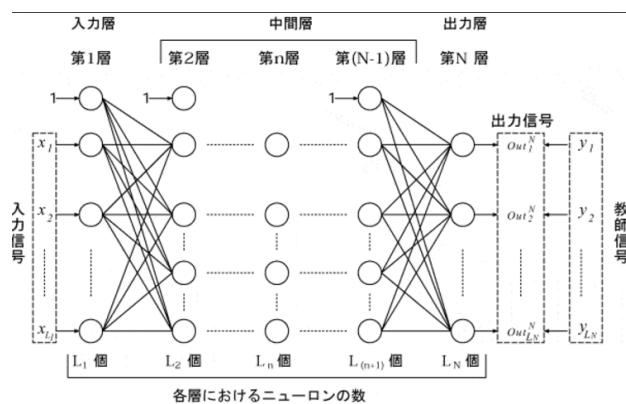
従来のニューロネットワーク

古典的Neural Network・パーセプトロン(1970年代)



線形分離できない

多層Neural NetworkとBack projection (1980年代)

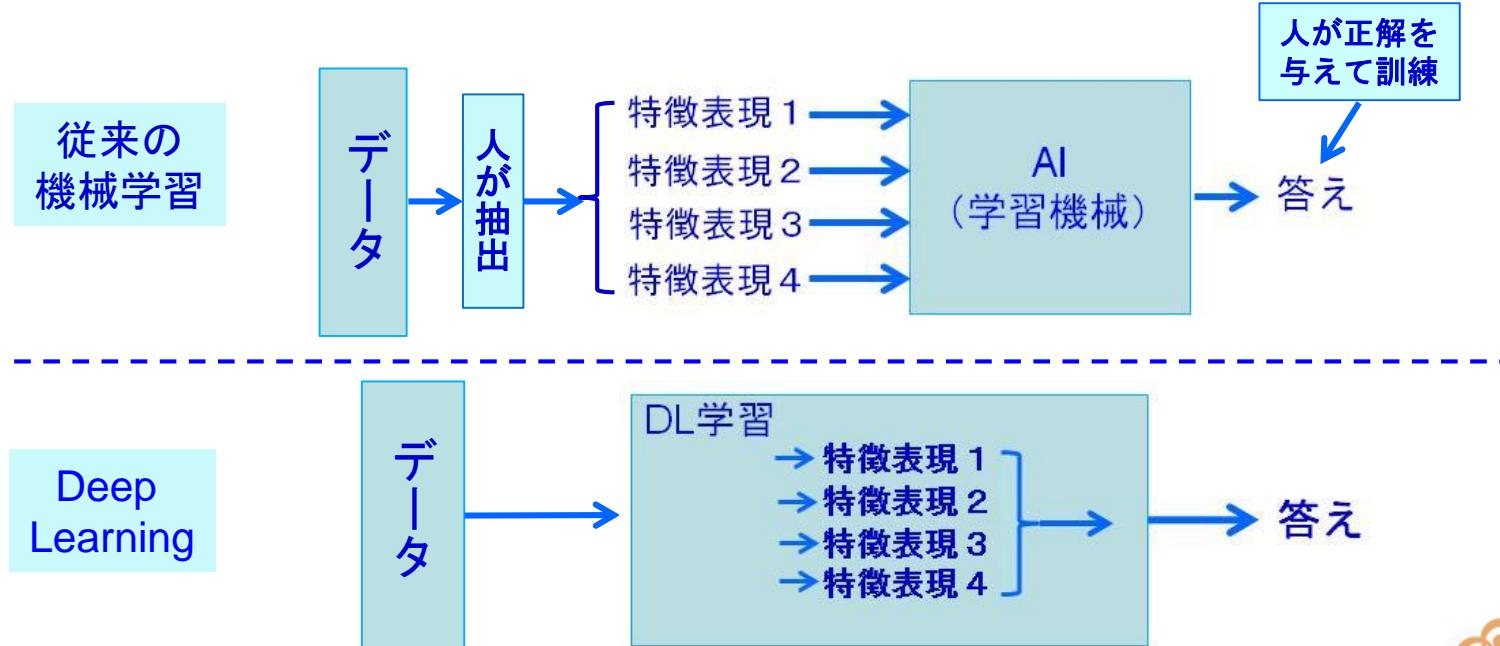


Back Propagation (1986 Rumelhart)
望ましい出力との誤差を教師信号として与える事により、次第に結合係数を変化させ、最終的に正しい出力が得られるようになる。
結合係数を変える事を学習と呼ぶ。
この学習方法には、最急降下法（勾配法）が使われる。出力層へ寄与の高いノードの重みが変更。

多層にわたる逆伝搬で修正感度減衰

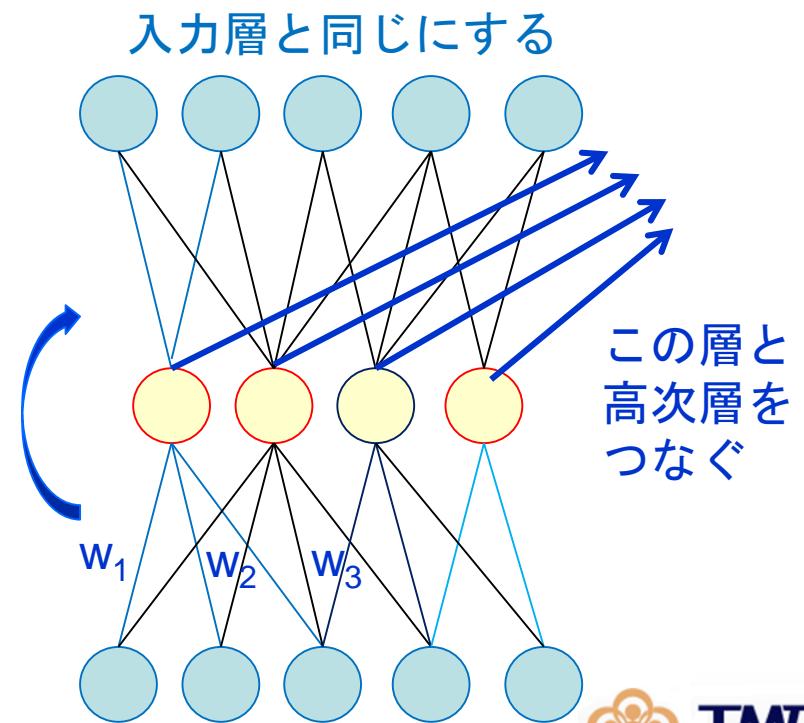
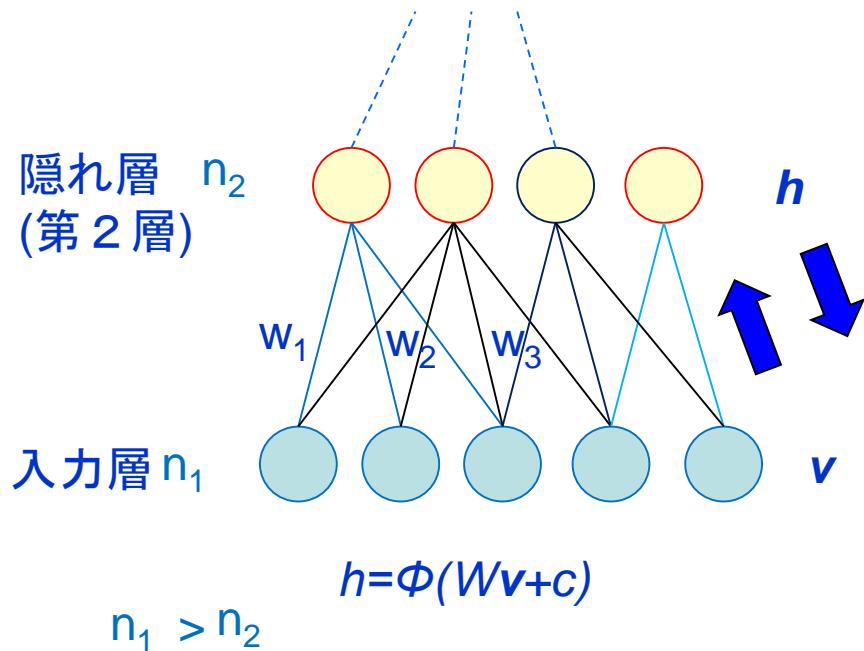
Deep Learning による 人工知能革命

- 機械学習のこれまでの限界
 - 「教師あり学習」
 - 分類対象の特徴と正解を与え学習機械（AI）を構築
- Deep Learningの革命性
 - 「教師なし学習」
 - 対象の特徴表現や対象の高次特徴量を自ら学ぶ



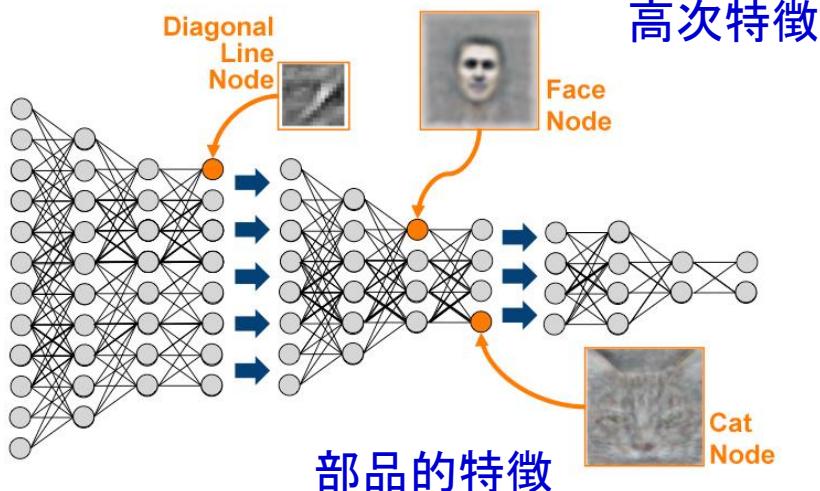
DLの革命点 Autoencode 1

- 対象に固有な**内在的特徴**を学ぶ自己符号化の原理
- 格段ごとに入力を少ない中間層を介して復元できるかを行なう
- 次元を圧縮されて可及的に復元する
 - できるだけ復元に効果的な特徴量を探索する
 - 内在的な特徴量**を見出す

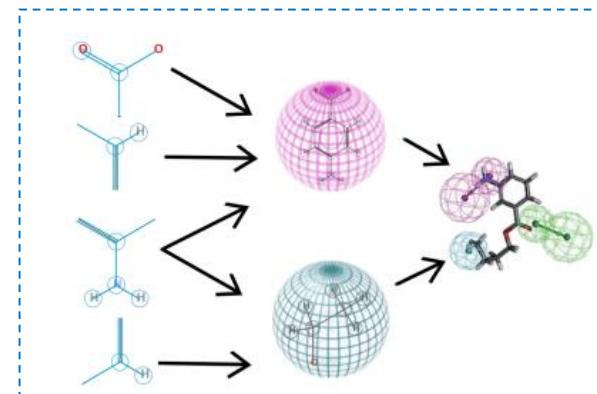


DLの革命点 Autoencode 2

- 各層ごとに自己符号化を行うので**何層でも組める**
→ **各層間で「自己符号化」の積上げ** (autoencoder stack)
- 第一層で学習した特徴量を使って次の階層を作るので**高次の特徴量**が作られる
- 特徴的表現と概念を結びつけるため「**教師あり学習**」が最後に必要。
- 自動特徴抽出によってこれまでの学習手法の限界を克服した
→ 内在的な特徴量による構造的理解
- 人間の「思考の枠組み」を超えた正解の低次
 - 「アルファGo」が定石がない手で碁の名人に勝つ



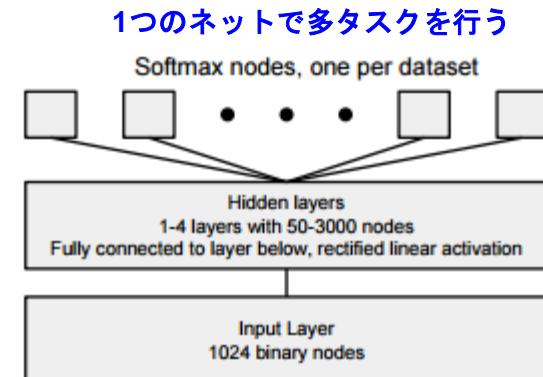
Pharmacophoreの摘出



Deep Learningの創薬へ応用

Deep learning: 創薬からの注目

- 創薬を巡る状況
 - 平均14年、約1000億円を超える費用
 - 市場化された新薬の減少
 - 創薬に費やす期間・コストを低減したい
- Kaggle (データサイエンス競技会)にMerck社が出題 Molecular Activity Challenge (2012).
 - 15データセットから異なった構造活性相関のデータを学習して構造から分子の生物学的活性を予測するモデルの開発コンテスト
 - 勝利したモデルはdeep learning を用いたモデル
- Google in collaboration with Stanford (2015)
 - Stanford 大学の Pande 研究室と共同研究 バーチャルドラッグスクリーニングに対する deep learningによるツール開発 "Massively Multitask Networks for Drug Discovery"



Artificial Intelligenceと創薬

- 標的分子選択と妥当性検証
 - 適切な分子標的の選択
- Virtual screening と選択
 - 適切な化合物に対するクラス判定
 - 研究例 : ChEMBLに対するdeep learning
 - 13 M 化合物特徴量 (ECFP12), 1.3M 化合物, 5k 薬剤標的
 - Ligand-based 標的予測, 7種の予測法とAUC比較
 - Deep learning: SVM, k-nearest nb, logistic回帰より優位
 - DLで構造活性相関を学習する
 - 特徴量の抽出、薬理機序への理解
 - リード最適化
- システム薬理学
 - ネットワーク病態学よりの創薬戦略
 - 他のシステムへの影響(毒性, 副作用)

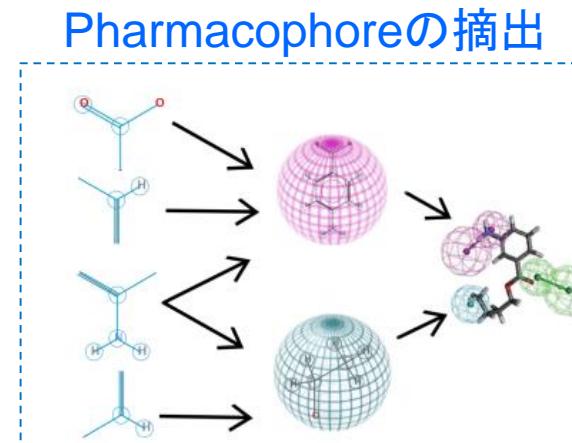


Figure . Hierarchical nature of fingerprint features: by combining the ECFP features we can build reactive centers. By pooling specific reactive centers together we obtain a pharmacophore that encodes a specific pharmacological effect.

Artificial Intelligenceと創薬

- 標的分子選択と妥当性検証
 - 適切な分子標的の選択
- Virtual screening と選択
 - 適切な化合物に対するクラス判定
 - 研究例 : ChEMBLに対するdeep learning
 - 13 M 化合物特徴量 (ECFP12), 1.3M 化合物, 5k 薬剤標的
 - Ligand-based 標的予測, 7種の予測法とAUC比較
 - Deep learning: SVM, k-nearest nb, logistic回帰より優位
 - DLで構造活性相関を学習する
 - 特徴量の抽出、薬理機序への理解
 - リード最適化
- システム薬理学
 - ネットワーク病態学よりの創薬戦略
 - 他のシステムへの影響(毒性, 副作用)

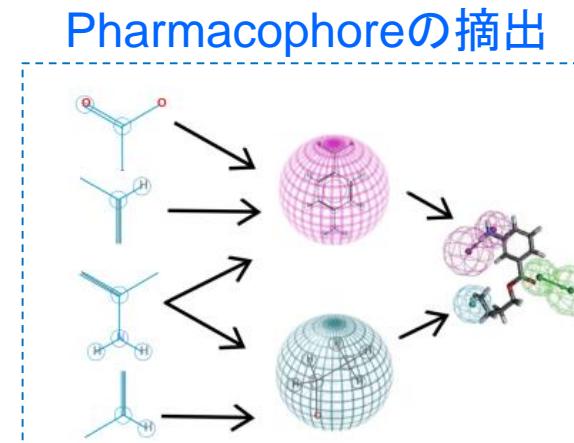


Figure . Hierarchical nature of fingerprint features: by combining the ECFP features we can build reactive centers. By pooling specific reactive centers together we obtain a pharmacophore that encodes a specific pharmacological effect.

我々の研究室での Deep Learningを用いた 創薬・DR 研究

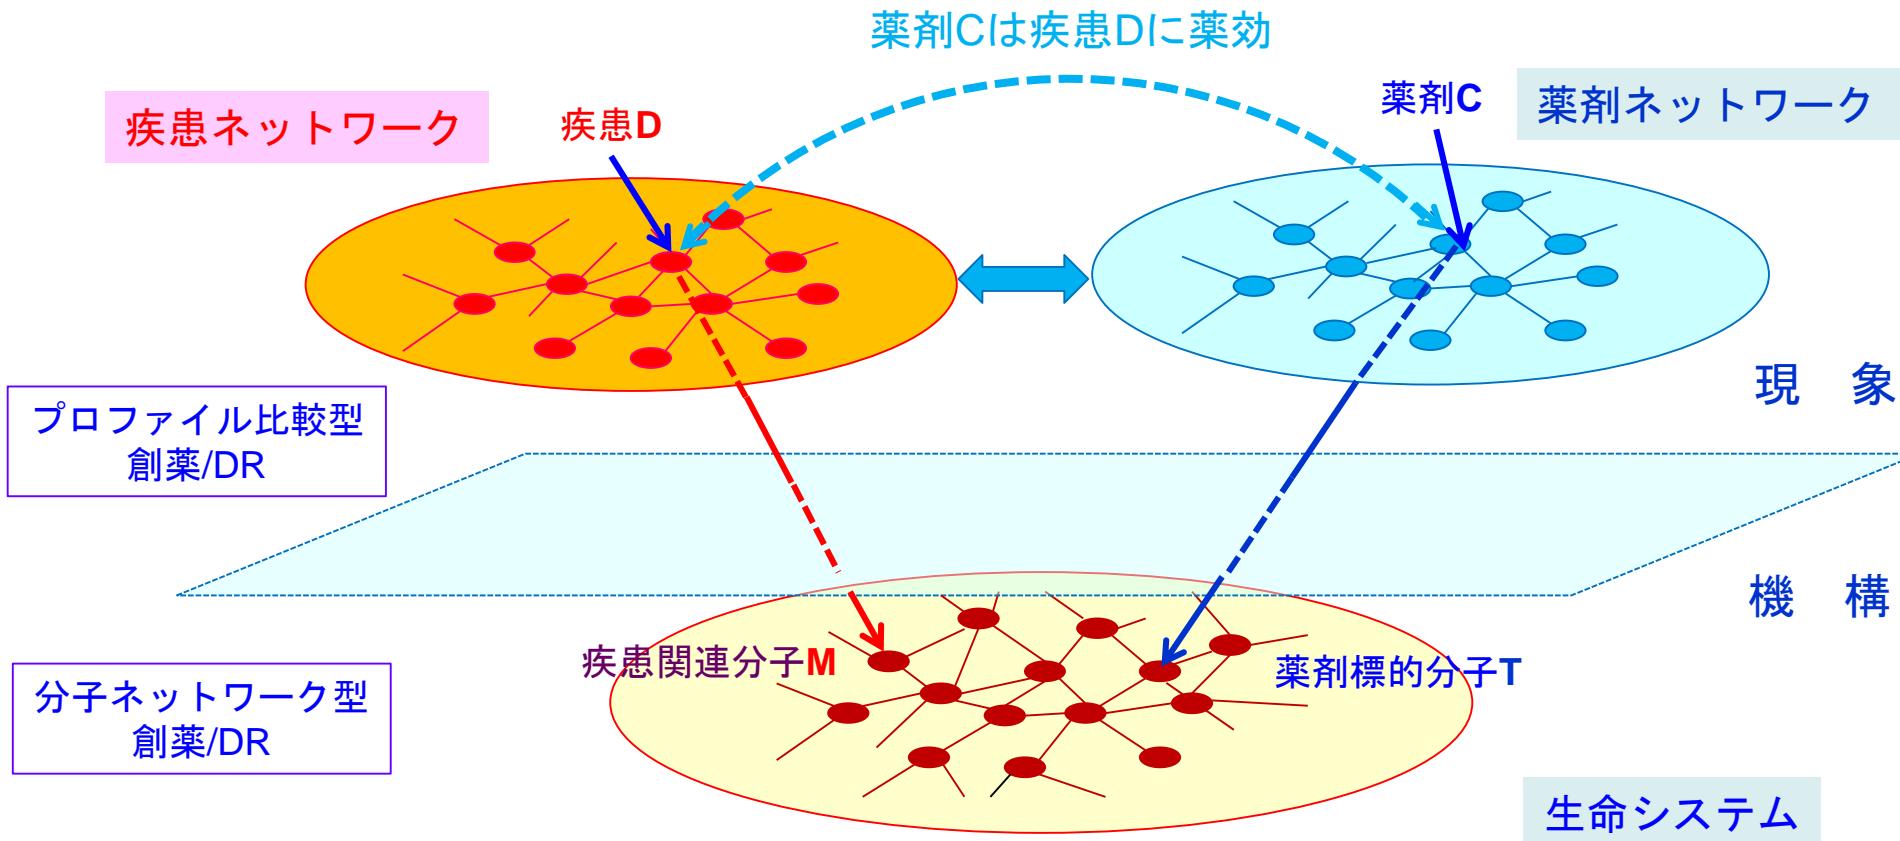
長谷武志・辻真吾・田中博

東京医科歯科大学
次世代生命医学研究所



プロファイル型計算創薬の原理

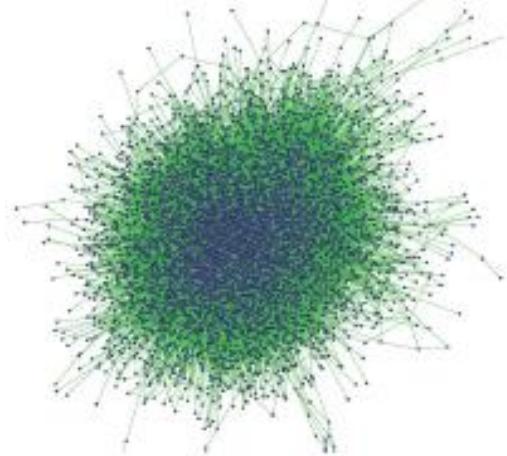
3層生体・薬剤ネットワークのFramework



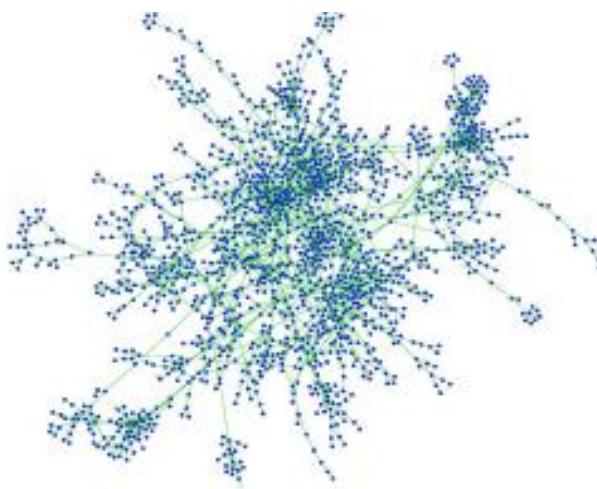
Feasibility Studyとしての 従来の機械学習での試み

生体ネットワークの3種類のタンパク質ネットワーク

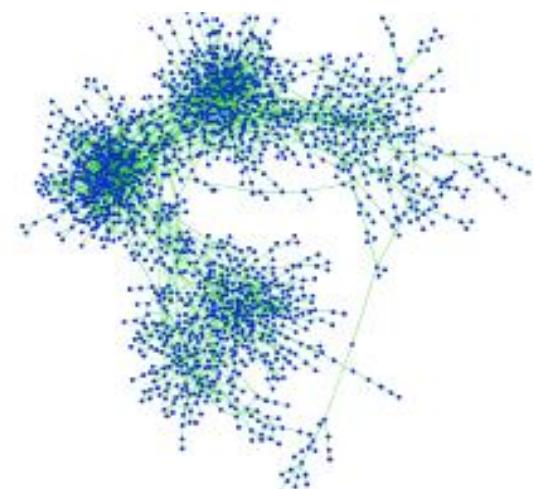
使用したデータベース



タンパク質相互作用ネットワーク



合成用量致死ネットワーク



合成致死ネットワーク

3種のネットワークと、薬剤と標的分子の情報を、訓練
データ・試験データの構築に用いた。



Step 1：ネットワーク解析を行い、機械学習モデルを生成するための特徴量を抽出する。

Step 2：機械学習を用いて対象疾患（疾患A）に対する新規標的分子を予測する

Step 3：予測された新規標的分子をベースにして、この疾患Aに対する新しいDRの薬剤を推測する

Step 1 : Network解析による各遺伝子の特徴量の抽出

そのノードのネットワーク特徴量を表す21種のネットワーク統計量を、各遺伝子に対して、各ネットワークを解析して算出した合計63種のネットワーク統計量を各遺伝子の特徴量として予測モデルの構築に用いた。

1. 次数中心性（他のタンパク質との結合次数が多い）
2. 近接中心性

他の全ノードとの距離の平均、ネットワークの中心に位置する程小さい、すなわち他の位置ノードと全般的に「近い」

3. 媒介中心性

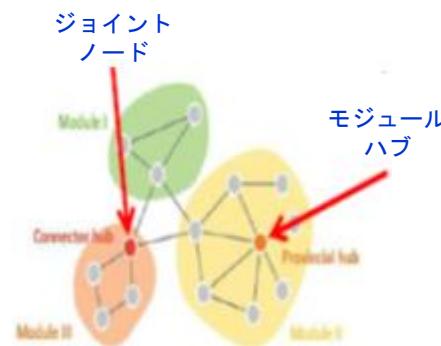
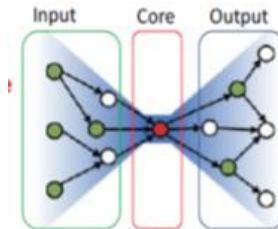
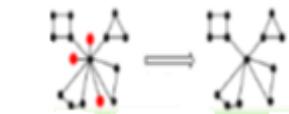
ネットワーク内の各ノード間を繋ぐ様々なパスが対象となるタンパク質をどれだけの頻度で通過するか、通過する頻度の割合が高い程、中心性がある

4. 蝶ネクタイ構造指標：

ネットワークに様々なノードから入力信号が入ってくると、中心的なコアで一旦集約されて様々な遺伝子へと拡散する構造 (bow-tie)においてコア部にいるか、両末端部にいるかを表す指標である。

5. モジュール指標

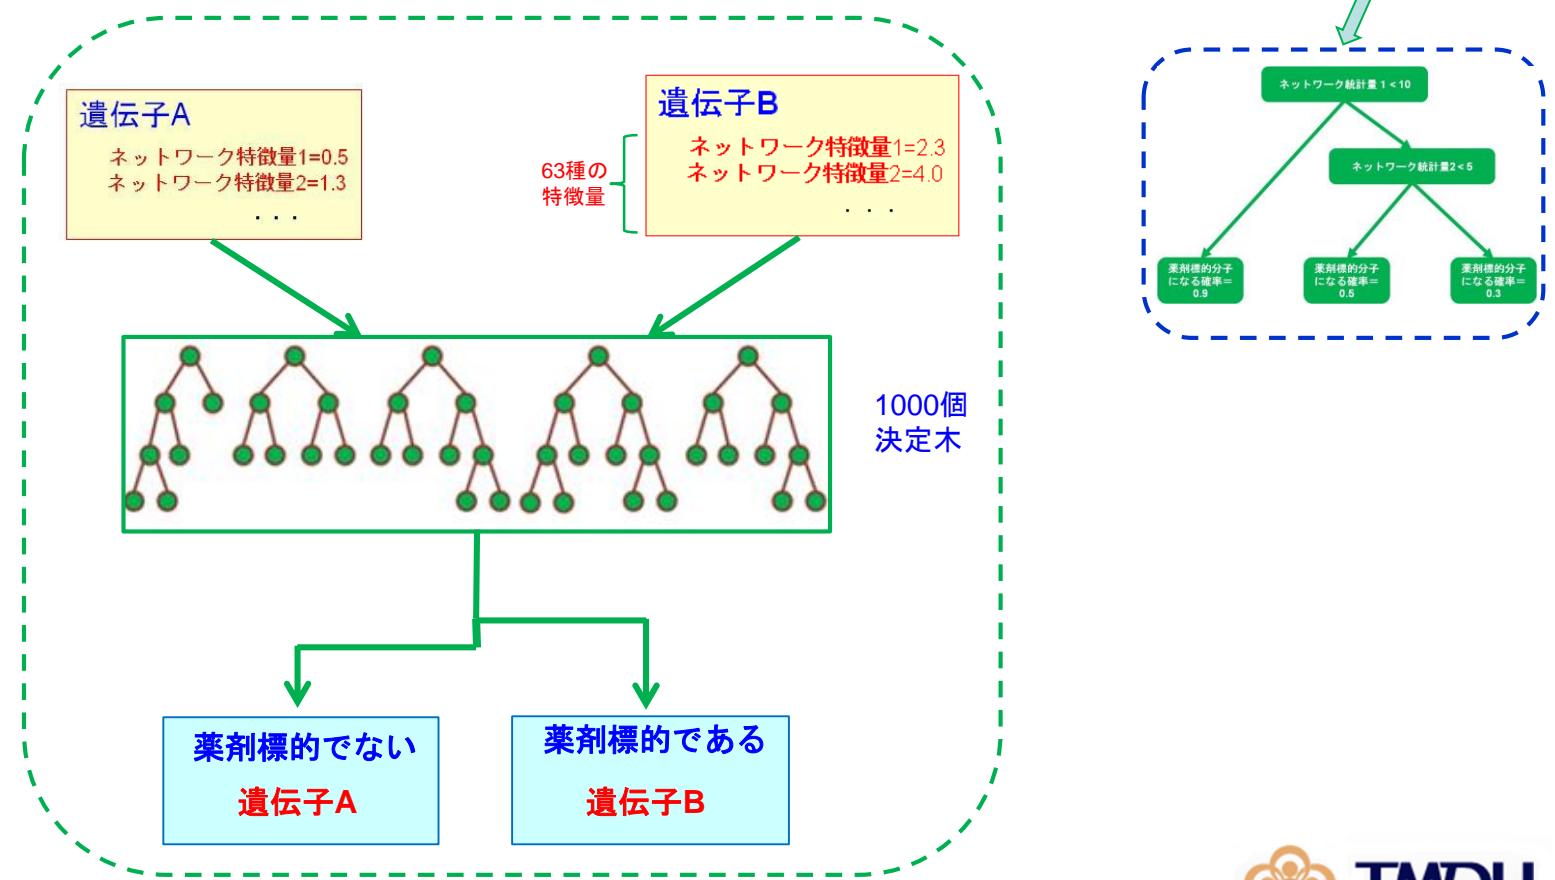
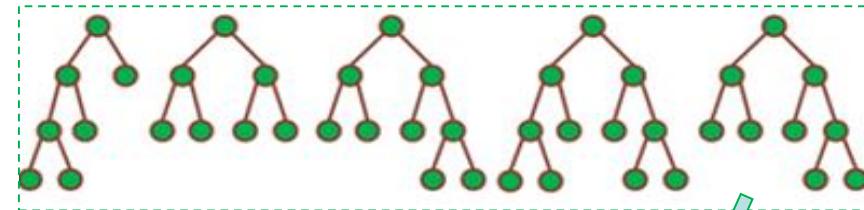
ネットワークが幾つかのモジュールに分かれる（積み木方式）ときモジュール間を繋ぐノードか、各モジュールのハブなどの指標である。



Step 2 機械学習モデルによる決定木

Random Forest

63個の特徴量からランダムに
いくつかの特徴量を選んで判別
ルールの決定木を1000個作成



＜疾患- 標的分子＞予測結果

Target disease	Top 25 genes for potential novel drug target for a target disease
Anti-Alzheimer's disease	SOCS1 ; <i>Bardet-Pieper syndrome 2; PRKCB; TBLB; UBB; HSPG2A1A; HSPG2; PARD6A; BLNK; PRKCI; YES1; PPP3CA; MMP11; SPTAN1; PTPRC; FBLN1; RPLP1; FAM107A; TRADD; NR4A1; LAT; NF2; PRKCE; KIT; NID1; S1PR1; CNR1; MTNR1A; CCL4; F2; TEC; L8; CRHR1; AGTR2; OPRD1; IL8RA; RNF43; RHO; SP6; RAB13; DRD4; IL8RB; MMP9; MMP2; OPRM1; IL1B; GNAS; S1PR3; KIT; GRM2</i>
Anti-Anxiety	
Anti-Rheumatoid	<i>SLC22A5; GRASP; KIT; SLC22A4; CFH; COX1; HSP90AA1; UBB; DHRS3; SCTR; ADORA1; NCOR2; C6orf47; NR4A1</i>
Anti-Breast Cancer	<i>SHC1; NFKB1; RELA; ID2; RAC1; SRC; RUX1; HDAC2; I</i>
Anti-Colorectal	
Anti-Pancreatic	
Anti-Melanoma	<i>RANBP9; HNRNPA0B1; PSEN1; P</i>
<p>Review</p> <p>SOCS1 and SOCS3 in the control of CNS immunity</p> <p>Brandi J. Baker, Lisa Nowoslawski Akhtar and Etty N. Benveniste Department of Cell Biology, The University of Alabama at Birmingham, Birmingham, AL 35294-0006, USA</p> <p><i>Trends in Immunology</i> Vol.30 No.8</p>	
<p>しかし、SOCS1は上流の遺伝子なので、この下流の遺伝子を標的にした方が、長期投与には良いとも考えれる。</p>	

SOCS1はJAK/STAT pathwayを介してサイトカインの応答を変動させ、中枢神経系の炎症を制御



TMDU

Step 3 : 疾患-標的分子リンクの同定よりDRへ

機械学習で予測された、新規標的情報(アルツハイマーと標的の情報,標的が新規標的分子、青いリンク)を、既知の薬剤一標的一疾患リンクをマップし薬剤の新しい適用疾患（赤リンク）を予測

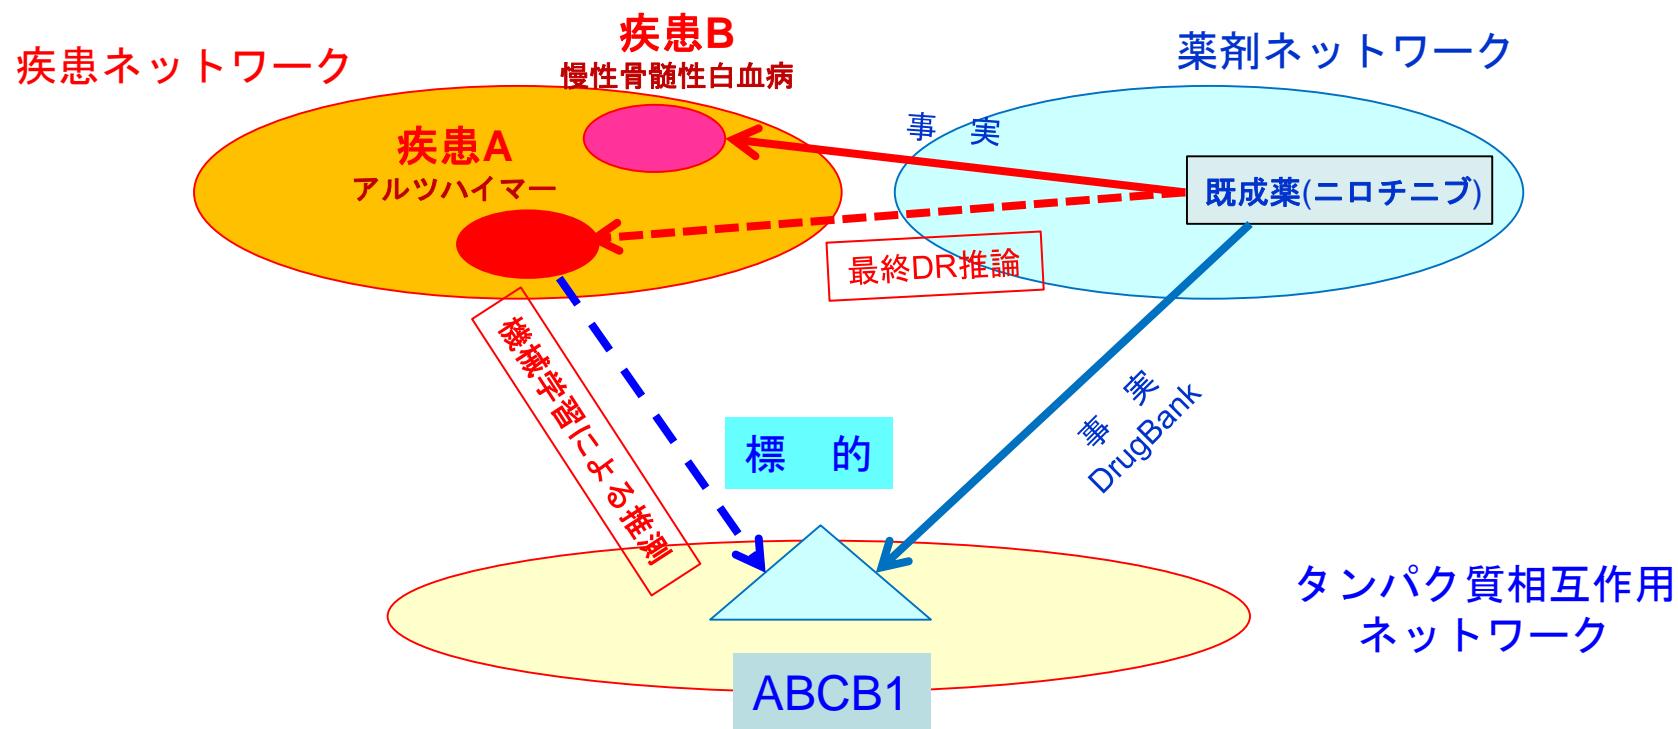


Table 3. Predicted repositionable drug candidates

Target disease	Candidate repositionable drug
Anti-Alzheimer's disease	Imatinib; Marimastat; Nilotinib; Regorafenib; Sorafenib; Tamoxifen; Urokinase
Anti-Anxiety	3-Methylfentanyl; Agomelatine; Amitriptyline; Amoxapine; Antihemophilic Factor; Apomorphine; Aripiprazole; Bromocriptine; Buprenorphine; Butorphanol; Cabergoline; Canakinumab; Captopril; Chlorpromazine; Coagulation Factor IX; Codeine; Dextromethorphan; Dextropropoxyphene; Dopamine; Drotrecogin alfa; Ethylmorphine; Etorphine; Fentanyl; Halothane; Hirulog; Hydrocodone; Hydromorphone; Imatinib; Ketamine; Ketobemidone; L-DOPA; Lepirudin; Levallorphan; Levorphanol; Lisuride; Loperamide; Lopapine; Marimastat; Melatonin; Menadione; Methadone; Methadyl Acetate; Methotrimeprazine; Minocycline; Morphine; Naloxone; Naltrexone; Nilotinib; Olanzapine; Ondansetron; Oxycodone; Oxymorphone; Paliperidone; Pergolide; Pethidine; Pramipexole; Promazine; Propiomazine; Quetiapine; Regorafenib; Remifentanil; Remoxipride; Risperidone; Ropinirole; Rotigotine; Sorafenib; Sufentanil; Suramin; Thiochylperazine; Ziprasidone
Anti-Rheumatoid	Acetylcholine; Adenosine; Amiloride; Aminohippurate; Aminophylline; Amphetamine; Ampicillin; Azidocillin; Benzylpenicillin; Cefalotin; Cefdinir; Cefixime; Cephalexin; Choline; Cimetidine; Clonidine; Cyclacillin; Desipramine; Diphenhydramine; Dopamine; Dyphylline; Enprofylline; Epinephrine; Furosemide; Grepafloxacin; Histamine Phosphate; Imatinib; Imipramine; Insulin; Isophane; Ipratropium bromide; L-Arginine; L-Carnitine; Levofloxacin; Lidocaine; Lithyronine; Lomefloxacin; Mepyramine; Methamphetamine; Niacin; Nicotine; Nilotinib; Norepinephrine; Norfloxacin; Ofloxacin; Oxtriphylline; Pentoxifylline; Probenecid; Procainamide; Quinidine; Quinine; Regorafenib; Rifabutin; Secretin; Sorafenib; Spermine; Telegadenoson; Testosterone; Tetraethylammonium; Theophylline; Thiamine;

Neuroscience 304 (2015) 316–327

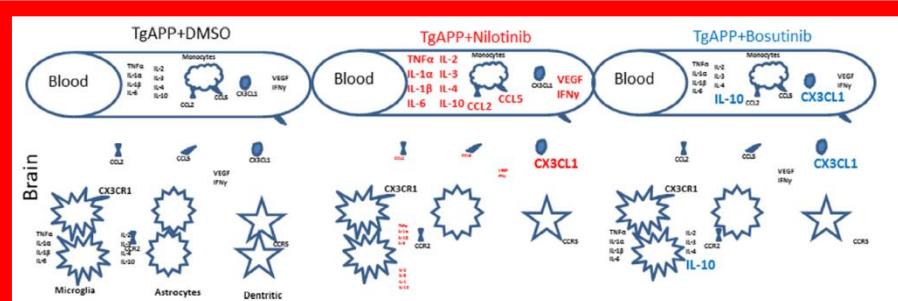
慢性白血病の抗がん剤であるニロチニブがアルツハイマーのDR薬剤として選定

NILOTINIB AND BOSUTINIB MODULATE PRE-PLAQUE ALTERATIONS OF BLOOD IMMUNE MARKERS AND NEURO-INFLAMMATION IN ALZHEIMER'S DISEASE MODELS

I. LONSKAYA,^a M. L. HEBRON,^a S. T. SELBY,^a
R. S. TURNER^b AND C. E.-H. MOUSSA^{a*}

^a Department of Neurology, Laboratory for Dementia and Parkinsonism, Georgetown University Medical Center, Washington D.C. 20007, USA

^b Department of Neurology, Memory Disorders Program, Georgetown University Medical Center, Washington D.C. 20007, USA



Deep Learningによる 創薬・DR

Deep Learningによる創薬・DR

1) 生体ネットワーク (PPIN) 特徴量の抽出

- タンパク質相互作用ネットワーク(PPIN)のネットワーク結合を学習し特徴表現を出力。
- n個のタンパク質間相互作用ネットワーク
 - n列のn次元ベクトルに展開
 - リンクがある成分は1に他は0のベクトル

2) 多層Stacked Auto-encoderのDLで学習.

- 特徴量の「教師無し」学習
- 次元圧縮による特徴量出力

3) DL特徴量の精錬化および正例の増加

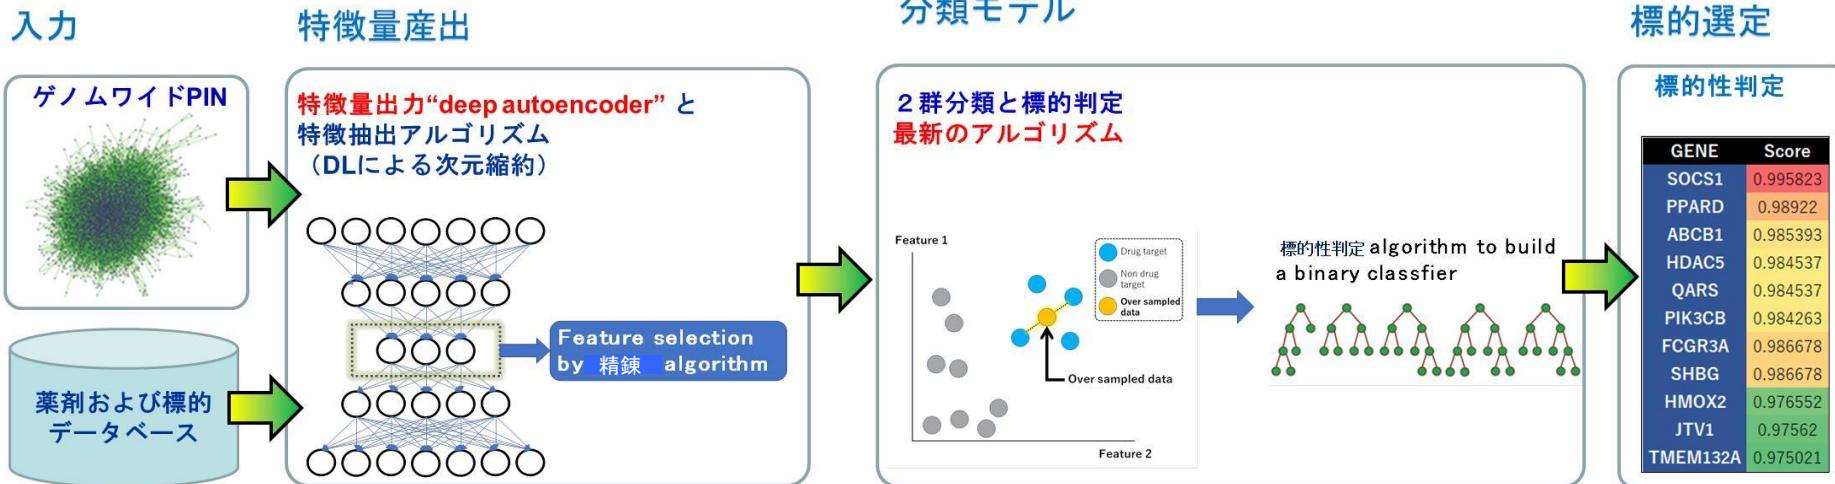
4) DL特徴量を用いた機械学習分類アルゴリズム

- ネットワーク・タンパク質の標的性の判定

Deep Learningによる創薬・DR

結論部 DrugBankを利用した 当該分子を標的とする既製薬剤の探索

既製薬剤がない→新規薬剤探求（創薬）
既製薬剤がある→DRの検討



従来の機械学習 (Random Forrest)と同じ成果は得られている

DL型NNへの期待と困難点

- 医療・創薬の応用は開始段階で応用成功例は少ない
 - 本質的に「教師なし学習」:人間が思いつかない解を提示
 - 画像分類・解釈と文章理解が優れているので、遺伝子発現プロファイル解析や病態推移の理解への応用が期待される
 - 例:ヒトmicrobiomeの分類・階層的表現を得た
 - 6つのがんで遺伝子発現をmiRNAとともに分類した。
 - 異なったMicroarrayを含むがん発現を分類の特徴表現を導き分類した。
 - Convolution ネットワークを使用して画像としての遺伝子発現を分類した。
 - 遺伝子発現プロファイルの自動アノテーション
- DL型ニューラルネットの困難点
 - 特徴表現を自己学習するが基本的にはBlack Box
 - 大量のデータを必要とする
 - DL型NNには、ハイパーパラメータが多種類があり、使用に関して選択問題が残る
 - 計算時間が長く、コストが大きい。

AI創薬/DRの方向性

- 我々の研究の「ネットワーク解析と機械学習に基づいたDR」
 - 試行として機械学習を適応した特徴量抽出で精度はRandom Forrestでも精度は出る
 - ネットワーク特徴量を与えるのではなく、ネットワークの結合情報の全ての情報を与え Stacked Autoencoder で特徴量を学習させる
- AI創薬の基本方針
 - 創薬・DRが根拠とする3層生体ネットワーク Frameworkのもとで、Deep Learningを中心とする機械学習・知識発見の戦略が期待できる

今後の戦略・方向

1. AI創薬の「枠組み」・実行方向は
「見えてきた」
2. 本年中に、いよいよAI創薬の実装に
着手しなければならない
3. 製薬企業、IT企業、医療機関を束ねた
集中的プロジェクトを推進するために
「AI創薬コンソーシアム」を設立する
必要がある

ご清聴有難う御座いました