




日本人疾患ゲノム情報統合データベースMGeNDとキュレーション支援システムの開発

鎌田 真由美, 中津井 雅彦, 小島 諒介, 奥野 恭史 (京都大学大学院 医学研究科)

研究の概要


- ゲノム医療では、解析で得られるバリアントに対する臨床的な解釈付け（キュレーション）に基づき治療方針決定を行う
- 適切なキュレーションには、民族集団における遺伝的背景の違いを考慮する必要がある
→ 日本人集団から得られるゲノム情報と疾患特異性・臨床特性情報を集約した統合データベース MGeND (Medical Genomics Japan Variant Database) の開発
- これまでに、「がん」「希少・難治性疾患」「認知症」「感染症」「難聴」を主な対象疾患とし、各疾患症例より得られた一塩基・構造バリアントとHLA領域多型の頻度情報を公開
- キュレーションには膨大な情報の包括的解釈が必要 → AI・NLP技術によるサポートシステムの開発





疾患ゲノム情報統合データベースMGeNDの開発

MGeND <https://mgend.med.kyoto-u.ac.jp>


トップ画面



変異詳細ページ



検索結果画面




遺伝子詳細ページ



疾患固有画面



【認知症】 APOE-genotype情報



データ登録フォーマット

SNV/INDEL

- ClinVar登録フォーマットに準拠した項目の設定
- 個人情報に考慮した統計値(頻度)での登録にも対応
- TSV/XML/VCF形式に対応

GWAS

- GWAS解析の共有に必要な項目を策定
- TSV形式に対応

HLA

- HLAタイプ解析で標準的に用いられるテーブル形式を踏襲
- Xlsx(TSV)形式に対応

登録可能なデータ

◆ 疾患名 (標準的な記載方法のもの)

◆ 遺伝子名

◆ 遺伝型情報 (Genotype)

- 1~数箇所程度のSNV・SNPまたはp値<10⁻⁴のSNPすべて
- 年齢(層)
- 性別(「不明」「混合」等を含む)
- 解析手法など

登録データ数 (2019年3月現在)

Disease area	Variants	GWAS	HLA allele data
Cancer	25,075(9041)	---	---
Rare/Intractable disease	13,513 (2459)	---	---
Infectious disease	2 (2) 155,098 (22,358)	1,306 (999)	
Hearing loss	122 (122)	---	---
Dementia	7631(7760) APOE: 12,298 (5196)	410 (414)	
Others	2721 (1998)	14,324,204 (0)	3261 (0)

疾患関連遺伝子キュレーション支援システムの開発

バリアントに対するキュレーションは、ゲノム医療のボトルネック

膨大な量の文献からエビデンスを調査する必要
幅広いデータベース情報を包括的に参照し、理解する必要



専門家でも1変異のキュレーションに約1時間、エキソームデータの臨床的評価には20~40時間が必要であるとも言われている…

論文からの知識抽出

変異と疾患の解釈に重要な論文をNLP技術を用いて自動的にピックアップ！

PubMed論文



固有表現抽出
テキストから「変異」「遺伝子」「疾患」を抽出

関係抽出

抜き出したエンティティ間の関係を推定

臨床的意義の推定

バリアントの疾患関連性をAIにより予測



制限共有システムとして実装&公開

各論文のアブストラクト

関連度・重要度をスコア化し、スコアノマ高めのものから順にリストアップ