

ОБЗОРЫ

УДК 57.052;57.056;575.827.2

РЕГУЛЯТОРНЫЙ ПОТЕНЦИАЛ SNP-МАРКЕРОВ В ГЕНАХ, КОДИРУЮЩИХ БЕЛКИ СИСТЕМ РЕПАРАЦИИ ДНК¹

© 2023 г. Н. П. Бабушкина^a, *, А. Н. Кучер^a

^aНаучно-исследовательский институт медицинской генетики,
Томский национальный исследовательский медицинский центр Российской академии наук,
Томск, 634050 Россия

*e-mail: nad.babushkina@medgenetics.ru

Поступила в редакцию 11.05.2022 г.

После доработки 16.08.2022 г.

Принята к публикации 16.08.2022 г.

Выявление широчайшего спектра локализованных в некодирующих участках генома однонуклеотидных полиморфизмов (SNP), ассоциированных с заболеваниями человека и патогенетически значимыми признаками, остро поставило вопрос по идентификации механизмов, объясняющих эти связи. Ранее нами выявлен ряд ассоциаций полиморфных вариантов генов, кодирующих белки репарации ДНК, с многофакторными заболеваниями. Для выяснения возможных механизмов, лежащих в их основе, нами проведена подробная аннотация регуляторного потенциала изучаемых маркеров с использованием ряда on-line ресурсов (GTxPortal, VannoPortal, Ensemble, RegulomeDB, Polymact, UCSC, GnomAD, ENCODE, GeneHancer, EpiMap Epigenomics 2021, HaploReg, GWAS4D, JASPAR, ORegAnno, DisGeNet, OMIM). В статье охарактеризован регуляторный потенциал следующих полиморфных вариантов: rs560191 (в гене *TP53BP1*), rs1805800 и rs709816 (*NBN*), rs473297 (*MRE11*), rs189037 и rs1801516 (*ATM*), rs1799977 (*MLH1*), rs1805321 (*PMS2*), rs20579 (*LIG1*). Приведена как общая характеристика изученных маркеров, так и информация по их влиянию на экспрессию “своего” и корегулируемых генов, на аффинность связывания факторов транскрипции. Рассмотрены опубликованные данные по адаптогенному и патологическому потенциалу этих SNP и о колокализованных с ними модификациях гистонов. Потенциальная вовлеченность на различных уровнях в регуляцию функционирования не только генов, в состав которых входят исследованные маркеры, но и близлежащих генов может объяснять ассоциированность изученных SNP с заболеваниями и их клиническими фенотипами.

Ключевые слова: SNP, ассоциации, регуляция экспрессии, сплайсинг, транскриционные факторы, гистоновый код, патогенность, консервативность

DOI: 10.31857/S0026898423010032, **EDN:** AXUPQD

ВВЕДЕНИЕ

Смещение акцентов в ассоциативных исследованиях от анализа генов-кандидатов к полногеномным ассоциативным исследованиям (GWAS) привело к открытию большого числа новых маркеров, ассоциированных с заболеваниями и количественными (в том числе и патогенетически значимыми) признаками. Оказалось, что среди ассоциированных однонуклеотидных полимор-

физмов (SNP) большая часть локализована в некодирующих участках генов и межгеновых регионах [1]. В то же время ассоциированные с заболеваниями генетические варианты, выявленные при проведении GWAS, необязательно “указывают” на наличие функциональной значимости для развития патологии именно этих вариантов, не всегда понятно, как эти варианты изменяют функциональное состояние клетки и в итоге работу организма в целом, определяя риск развития патологии. В этой связи в последние годы особенно активно стали развиваться биоинформационные подходы, позволяющие оценить функциональную значимость полиморфных вариантов не напрямую, а через существующие блоки сцепления, эпистатические взаимодействия с различными генами, “взаимоотношения” различных уровней регуляции.

¹ Дополнительная информация для этой статьи доступна по DOI 10.31857/S0026898423010032

Сокращения: enhD (enhancer-like distal element) – энхансерподобный дистальный элемент; enhP (enhancer-like proximal element) – энхансерподобный проксимальный элемент; GWAS (Genome-Wide Association Studies) – полногеномные ассоциативные исследования; SNP (single nucleotide polymorphism) – однонуклеотидный полиморфизм(ы); TF (transcription factor) – транскрипционный фактор; ИБС – ишемическая болезнь сердца.

К числу относительно новых генов, структурная вариабельность которых может вносить вклад в формирование предрасположенности к различным многофакторным заболеваниям, относятся гены, кодирующие белки систем репарации ДНК. Помимо вовлеченности в канцерогенез (чему посвящены многочисленные исследования), накапливаются данные о значимости этих генов при развитии заболеваний сердечно-сосудистой, пищеварительной, мочеполовой, скелетно-мышечной, гемопоэтической и других систем (см. обзор [2]). Ранее нами изучена вовлеченность 9 SNP в генах, кодирующих белки различных репарационных систем: *TP53BP1* (rs560191), *NBN* (rs1805800, rs709816), *MRE11* (rs473297), *ATM* (rs189037, rs1801516), *MLH1* (rs1799977), *PMS2* (rs1805321), *LIG1* (rs20579), – в развитие многофакторной патологии различной этиологии. Мы проанализировали около 1.5 тыс. образцов ДНК из банка ДНК НИИ медицинской генетики Томского НИМЦ РАН, полученных от пациентов с различными заболеваниями: изолированная аллергическая бронхиальная астма (БА) и смешанная БА в сочетании с артериальной гипертензией (БА_АГ), хронический вирусный гепатит С (ХВГС), туберкулез (ТБ), сердечно-сосудистые заболевания (ишемическая болезнь сердца (ИБС) и аутопсийный материал умерших в результате сердечно-сосудистого события (АУТ_ИБС)); а также от жителей г. Томска (популяционная выборка – К) и долгожителей (Гер) [3–8]. При незначительной подразделенности изученной популяции на субгруппы в соответствии с основными диагнозами пациентов (попарные $F_{ST} < 1\%$) выявлен неплохой дифференцирующий потенциал маркеров. При визуализации матрицы генетических расстояний видно (рис. 1), что первая координата отделяет контроль (К) и группы пациентов с ИБС и умерших в раннем возрасте от сердечно-сосудистых катастроф (АУТ_ИБС) от групп пациентов с другими заболеваниями. Это может свидетельствовать о малом вкладе изученных маркеров генов, кодирующих белки систем репарации ДНК, в развитие сердечно-сосудистой патологии, что согласуется с результатами ассоциативного анализа: прямых ассоциаций с патологией не выявлено, ассоциации зарегистрированы только с патогенетически значимыми признаками [3]. Вторая координата от кластера сердечно-сосудистой патологии и контроля отделяет группу умерших от сердечно-сосудистого заболевания, из чего можно предполагать вклад изученных маркеров в раннее развитие или в быструю прогрессию таких заболеваний и, как следствие, в ранние неблагоприятные исходы. От большого кластера прочих патологий вторая координата отделяет БА – изолированную форму и сочетанную с артериальной гипертензией, – что предполагает наличие вклада изученных маркеров в аллергическую компонен-

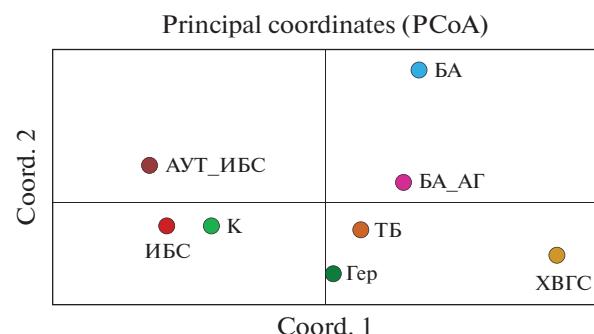


Рис. 1. Расположение изученных групп патологий в поле главных координат на основании генетических дистанций, рассчитанных по маркерам, локализованным в генах, кодирующих белки систем репарации ДНК. Расчет генетических дистанций по методу Nei и их визуализация выполнены с помощью приложения GenAlEx 6.503 [9]. ИБС – ишемическая болезнь сердца; АУТ_ИБС – аутопсийный материал умерших в результате сердечно-сосудистого события; ТБ – туберкулез; ХВГС – хронический вирусный гепатит С; БА – бронхиальная астма; БА_АГ – бронхиальная астма в сочетании с артериальной гипертензией; Гер – выборка долгожителей; К – средневозрастная популяционная выборка.

ту этих заболеваний. И это вполне возможно, так как белки репарационных систем вовлечены в V(D)J-рекомбинацию и переключение синтеза классов иммуноглобулинов. Результаты ассоциативного анализа, в свою очередь, также подтверждают этот вывод [4, 5, 8].

Таким образом, вклад изученных маркеров в развитие многофакторной патологии очевиден, хотя не все полученные ассоциации можно логично объяснить с точки зрения патогенеза анализируемых заболеваний. Для выяснения возможных механизмов фенотипической реализации установленных ассоциаций нами проведена подробная аннотация регуляторного потенциала изучаемых маркеров. Аннотация выполнена с использованием таких открытых ресурсов, как GTxPortal, VannoPortal, Ensemble, RegulomeDB, Polymap, UCSC, GnomAD, ENCODE, GeneHancer, EpiMap Epigenomics 2021, HaploReg, GWAS4D, JASPAR, ORegAnno, DisGeNet и OMIM.

ОБЩАЯ ХАРАКТЕРИСТИКА ИССЛЕДОВАННЫХ МАРКЕРОВ

Маркеры для анализа изначально выбирали с учетом их вероятной функциональной значимости, соответственно они располагались либо в кодирующей (rs560191, rs709816, rs1801516, rs1799977, rs1805321), либо в промоторной (rs473297, rs1805800, rs189037, rs20579) части генов (табл. 1), что предполагает влияние замены на изменения либо структуры белка, либо уровня экспрессии. Согласно рангу по RegulomeDB, наибольшим ре-

Таблица 1. Исследованные маркеры: локализация и функциональный класс

SNP ID: нуклеотидная замена	Хромосомная локализация	Ген/локализация в гене/замена ^a	RegulomeDB ^b ранг/шкала	MAF ^c (min–max)
rs560191: G>C	15q15.3	<i>TP53BP1</i> /ex 9/Asp358Glu	1f/0.554	0.526 (0.231–0.973)
rs473297: T>G	11q21	<i>MRE11</i> /5'UTR ^d (in1/ <i>ANCRD</i>)	1f/0.223	0.539 (0.346–0.652)
rs1805800: C>T	8q21.3	<i>NBN</i> /5'UTR	4/0.609	0.353 (0.167–0.500)
rs709816: G>A	8q21.3	<i>NBN</i> /ex10/Asp399	6/0.288	0.609 (0.319–0.925)
rs189037: G>A	11q22.3	<i>ATM</i> /5'UTR	2a/0.98	0.467 (0.138–0.703)
rs1801516: G>A	11q22.3	<i>ATM</i> /ex37/Asp1853Asn	7/0.184	0.067 (0.0004–0.237)
rs1799977: A>G	3p22.2	<i>MLH1</i> /ex8/Ile219Val	5/0.611	0.170 (0.006–0.360)
rs1805321: G>A	7p22.1	<i>PMS2</i> /ex11/Pro470Ser	5/0.135	0.358 (0.206–0.505)
rs20579: G>A	19q13.33	<i>LIG1</i> /5'UTR	5/0.304	0.173 (0.059–0.343)

^a Замена аминокислотного остатка в указанной позиции кодируемого белка; in – инtron, ex – экзон.

^b Функциональный класс по классификации RegulomeDB (<https://regulomedb.org/regulome-search/>): 1f – вариант экспрессионного локуса количественных признаков (eQTL) в мотиве связывания TF или в регионе гиперчувствительности к ДНКазе; 2a – вариант локализован в мотиве связывания TF и изменяет эти мотивы, а также в регионе гиперчувствительности к ДНКазе; 4 – вариант локализован в мотиве связывания TF и в регионе гиперчувствительности к ДНКазе; 5 – вариант локализован в мотиве связывания TF или в регионе гиперчувствительности к ДНКазе; 6 – нарушение мотивов связывания TF; 7 – другое.

^c Среднепопуляционная частота альтернативного аллеля.

^d 5'UTR – 5'-нетранслируемая область гена.

гуляторным потенциалом обладают rs560191 и rs473297, которые представляют собой eQTL-варианты, а также расположены в регионах связывания транскрипционных факторов (TF) или в регионах чувствительности к ДНКазе. Наименьший регуляторный потенциал предполагается для rs709816 (изменение мотивов связывания TF) и rs1801516 (ранг – “Другое”).

Вариант rs560191 в гене *TP53BP1* представляет собой миссенс-замену G/C в экзоне 9, приводящую к замене Asp358Glu в кодируемом белке (табл. 1). Средняя частота аллеля С составляет 0.526, варьируя от 0.213 у финнов до 0.973 у афроамериканцев. У африканцев и афроамериканцев в том же геномном положении зарегистрирована также замена G/T, частота аллеля Т – около 6×10^{-5} (<http://www.ensembl.org/index.html>, <https://gnomad.broadinstitute.org/>). Данный SNP локализован между двумя дистальными энхансерподобными регуляторными элементами: E1757875/enhD и E1757876/enhD (<https://genome.ucsc.edu/>, <https://www.encodeproject.org/>).

В гене *NBN* изучено две нуклеотидные замены: rs1805800 и rs709816 (табл. 1). rs1805800 представ-

ляет собой замену С/Т в 5'UTR гена *NBN*. Среднепопуляционная частота аллеля Т rs1805800 составляет 0.353, варьируя в пределах от 0.167 (африканские популяции Карибов и Барбадоса) до 0.500 у индийцев-гуджарати (<http://www.ensembl.org/index.html>, <https://gnomad.broadinstitute.org/>). Данный маркер находится на расстоянии 395 п.н. от промотора гена *NBN*; входит в состав промотора GH08J089980 и проксимального энхансерподобного элемента E2646296/enhP (<https://genome.ucsc.edu/>, <https://www.encodeproject.org/>, <https://www.genecards.org/>). Замена А/G (rs709816) в экзоне 10 гена *NBN* синонимичная (Asp399). В референсной последовательности описан аллель А, хотя фактически это производный аллель. Среднепопуляционная частота аллеля Г составляет 0.609, наименьшая частота зарегистрирована у жителей Англии и Шотландии (0.319), наибольшая – у населения Гамбии (0.925) (<http://www.mulinlab.org/vportal/index.html>, <http://www.ensembl.org/index.html>, <https://gnomad.broadinstitute.org/>). Эта сайленс-замена локализована менее чем в 5000 п.н. от дистального энхансерподобного элемента E2646270/enhD и энхансера GH06J089948

(<https://genome.ucsc.edu/>, <https://www.encodeproject.org/>, <https://www.genecards.org/>).

Два SNP изучено также в гене *ATM* (табл. 1). rs189037 представляет собой замену G/A в 5'UTR гена, локализованную в CpG-островке, в 29 п.н. от промотора гена *ATM*, внутри промотора GH11J108219, между промоторподобными элементами E1567620/prom (в 73 п.н.) и E1567621/prom (в 128 п.н.) (<https://genome.ucsc.edu/>, <https://www.encodeproject.org/>, <https://www.genecards.org/>). Среднепопуляционная частота составляет 0.467, варьируя от 0.138 у гамбийцев до 0.703 у населения Пакистана (<http://www.ensembl.org/index.html>, <https://gnomad.broadinstitute.org/>). rs1801516 – мисс-сенс-вариант G/A в 37 экзоне, приводящий к замене Asp1853Asn. Этот вариант локализован в мультирегионе взаимодействия *KDELc2/GH11J108219*, расположен на расстоянии 893 п.н. от дистального энхансерподобного элемента E1567660/enhD (<https://genome.ucsc.edu/>, <https://www.encodeproject.org/>, <https://www.genecards.org/>). Среднепопуляционная частота аллеля А составляет 0.0669, варьируя от 0.0004 у японцев до 0.2367 у финнов (<http://www.ensembl.org/index.html>, <https://gnomad.broadinstitute.org/>).

rs473297 в гене *MRE11* (табл. 1) представляет собой замену T/G в 5'UTR, локализованную в 79 п.н. от промотора GH11J094492, в 550 п.н. от проксимального энхансерподобного элемента E1561900/enhP, в регионе взаимодействия *MRE11/GH11J094492* (<https://genome.ucsc.edu/>, <https://www.genecards.org/>). Среднепопуляционная частота аллеля G составляет 0.539, варьируя от 0.346 у британцев и шотландцев до 0.652 у ишан из Нигерии. В этой же точке генома у жителей Восточной Азии описана замена T/A, частота аллеля А составляет менее 3×10^{-4} (<http://www.ensembl.org/index.html>, <https://gnomad.broadinstitute.org/>).

В экзоне 8 гена *MLH1* изучена несинонимичная замена A/G – rs1799977 (табл. 1), – ведущая к замене Ile219Val в кодируемом белке. Этот вариант локализован в мультирегионе взаимодействия *LRRKIP2/GH03J036988* (<https://genome.ucsc.edu/>, <https://www.genecards.org/>). Среднепопуляционная частота аллеля G составляет 0.170, варьируя от 0.006 (менде, Сьерра-Леоне) до 0.360 (тосканцы, Италия). В редких случаях в этой точке генома регистрируют замену A/T (описана в базе TOPMed) с частотой аллеля Т 1.5×10^{-5} (<http://www.ensembl.org/index.html>, <https://gnomad.broadinstitute.org/>).

rs1805321 (табл. 1) в гене *PMS2* представляет собой нуклеотидную замену G/A в экзоне 11, приводящую к замене Pro470Ser в кодируемом белке. Этот SNP локализован в 1512 п.н. от дистального энхансерподобного элемента E2531915/enhD (<https://genome.ucsc.edu/>, <https://www.encodeproject.org/>). Среднепопуляционная частота замены – 0.358, варьирует в пределах от 0.206 (у менде,

Сьерра-Леоне) до 0.505 (у британцев Англии и Шотландии) (<http://www.ensembl.org/index.html>, <https://gnomad.broadinstitute.org/>).

Замена G/A (rs20579) расположена в 5'UTR гена *LIG1* (табл. 1), в некодирующем участке экзона 2, она локализована в мультирегионах взаимодействия *LIG1/GH19J048121* и *PLA2G4C/GH19J048253*; в 158 п.н. от замены заканчивается проксимальный энхансерподобный элемент E1959701/enhP (<https://genome.ucsc.edu/>, <https://www.encodeproject.org/>). Среднепопуляционная частота аллеля А составляет 0.173, варьирует от 0.0594 (у японцев) до 0.343 (у йоруба и ишан в Нигерии) (<http://www.ensembl.org/index.html>, <https://gnomad.broadinstitute.org/>).

Таким образом, все анализируемые нуклеотидные замены локализованы в регионах (или рядом с ними), непосредственно регулирующих транскрипцию генов (промоторов, энхансеров и подобных им элементов), и, следовательно, могут обладать регуляторным потенциалом.

МОДИФИКАЦИИ ГИСТОНОВ, КОЛОКАЛИЗОВАННЫЕ С АНАЛИЗИРУЕМЫМИ МАРКЕРАМИ

Известно, что в определении функционального состояния отдельно взятых фрагментов генома важнейшую роль играют посттрансляционные модификации гистонов (“гистоновый код”) [10]. Для анализа гистоновых модификаций в регионах локализации исследуемых SNP были использованы данные репозитория Epimap Epigenomics 2021, представляющего собой интегральный ресурс, обобщающий эпигеномные карты по 869 биообразцам, отнесенным к 33 категориям тканей (<http://compbio.mit.edu/epimap/#chromatin-states>) [11]. Под биообразцами при этом понимаются как клетки различных тканей (в норме на разных стадиях развития и при патологии), так и различные клеточные линии и их дериваты.

Для кодирующих регионов генов, в которых локализовано пять привлеченных к рассмотрению полиморфных вариантов, отмечается небольшое количество гистоновых модификаций, характерных для активно транскрибируемого хроматина. Так, для всех пяти локусов выявлено trimетилирование лизина в позиции 36 гистона H3 (H3K36me3), типичное для открытого хроматина и способствующее элонгации транскрипции (табл. 2) (<http://www.mulinlab.org/vportal/index.html>, <http://compbio.mit.edu/epimap/#chromatin-states>). Другие эпигенетические метки (также характеризующие активную транскрипцию) встречаются редко, в отдельных типах клеток. Так, с регионом гиперчувствительности к ДНКазе колocalизованы четыре из исследованных замен в кодирующих участках генов: rs560191 (в быстро-растущем клоне линии LNCaP, звездчатых

Таблица 2. Колокализованные с анализируемыми маркерами модификации хроматина

а имputed) – предполагаемая (вмененная), ob (observed) – наблюдаемая колокализация с модифицированным гистоном белком хроматина.

^b Биообразцы представляют собой отдельные ткани/клеточные линии/клетки/индивидуированные стволовые клетки/дериваты и т.д. (данные ЕроМар Ергеномикс, <http://comppbio.mit.edu/erpmar/#chromatin-states>). Светло-серая заливка – способствующие транскрипции модификации, колокализованные с заменами в кодирующих регионах, темно-серая – с заменами в 5UTR; черная заливка – модификации-репрессоры.

клетках печени, гепатоцитах, лимфобластоидной клеточной линии GM19239, линии фибробластов легких AG08396), rs709816 (в эмбриональных клетках желудка), rs1801516 (в гематопоэтических стволовых и В-клетках при миелоидном лейкозе), rs560191 (в быстрорастущем клоне линии LNCaP, звездчатых клетках печени, гепатоцитах, лимфобластоидной клеточной линии GM19239, линии фибробластов легких AG08396), rs1799977 (в клетках аденокриномы простаты) (<http://www.mulinlab.org/vportal/index.html>, <http://compbio.mit.edu/epimap/#chromatin-states>). Кроме того, rs560191 в гене *TP53BP* колокализован с регионом связывания РНК-полимеразы II (в клетках влагалища), с ацетилированным лизином в позиции 23 гистона H3 – H3K23ac (в клетках трофобласта, дериватах H1-hESC), с H3K79me1 (в мезенхимальных и мезодермальных стволовых клетках, дериватах H1-hESC; в эмбриональных стволовых клетках линии H9; в эмбриональных фибробластах легкого линии IMR-90), с H3K27ac и H3K9ac (в гепатоцитах), H4K20me1 (в эмбриональных клетках, подобных стволовым, – линия H1-hESC) (<http://www.mulinlab.org/vportal/index.html>, <http://compbio.mit.edu/epimap/#chromatin-states>). Нуклеотидная последовательность, содержащая rs709816 в гене *NBN*, колокализована с H3K27ac (большеберцовые нервы), с H3K79me2 (нейробластома) (<http://www.mulinlab.org/vportal/index.html>, <http://compbio.mit.edu/epimap/#chromatin-states>). rs1801516 в гене *ATM* колокализован с H4K20me1 (колоректальная аденокарцинома) (табл. 2) (<http://www.mulinlab.org/vportal/index.html>, <http://compbio.mit.edu/epimap/#chromatin-states>).

Иной паттерн модификаций гистонов колокализуется с маркерами в 5'UTR генов (табл. 2). Каждый из этих SNP колокализован с пятью модификациями хроматина: регионом гиперчувствительности к ДНКазе, H3K27ac и H3K4me2 (характеризующими энхансерные последовательности), H3K4me3 и H3K9ac (способствующими активации транскрипции). Три маркера колокализованы с модификацией H3K4me1 (также характерной для энхансерных последовательностей): rs473297 в 141, rs1805800 в 255 биообразцах и rs20579 в эпителиальных клетках меланомы и нейроэпителиоме. С модификацией, поддерживающей активацию транскрипции и элонгацию, H3K79me2, колокализованы следующие маркеры: rs473297 в 732, rs20579 в 235 и rs189037 в 6 биообразцах (в различных субпопуляциях Т-лимфоцитов, а также в Т-лимфоцитах при остром лимфобластном лейкозе и в лимфобластоидной клеточной линии). Модификация H3K36me3, поддерживающая элонгацию транскрипции, колокализуется с rs20579 (в 48 образцах) и rs189037 (в Т-лимфоцитах, гладкомышечных клетках двенадцатиперстной кишки, фибробластах краиней плоти).

Два локуса (rs1805800 и rs189037) находятся в открытом хроматине с сайтами связывания таких белков, как CTCF, SMC3, EP300, H2AFZ. rs189037, кроме этого, колокализован с сайтом связывания РНК-полимеразы II и RAD21. Известно, что транскрипционный репрессор CTCF связывается с инсуляторами генов [12]. Кроме того, у млекопитающих CTCF совместно с когезиновым комплексом (в который входят в том числе SMC3 и RAD21) и гистоном H2AFZ принимает участие в организации хромосом в топологически ассоциированные домены [13, 14]. Следовательно, нуклеотидные последовательности, в которых находятся rs1805800 и rs189037, имеют важное топологическое значение и любые изменения в их структуре могут способствовать развитию патологических состояний.

Два маркера колокализованы с H3K79me1 (активация элонгации): rs20579 (в эмбриональных фибробластах легкого, дериватах линии H1-hESC – мезенхимальных и мезодермальных стволовых клетках), rs189037 (в клетках трофобласта – дериваты из H1-hESC). С монометилированным лизином в положении 20 гистона H4 (H4K20me1), также поддерживающим активацию транскрипции [15], колокализованы rs473297 (в двух клеточных линиях Т-лимфоцитов при остром лимфобластном лейкозе) и rs20579 (в Т-лимфоцитах при остром лимфобластном лейкозе и в эндотелиальных клетках пупочной вены новорожденного).

rs189037 в гене *ATM* в различных эмбриональных тканях/дериватах колокализован с целым рядом гистоновых модификаций, также поддерживающих активацию транскрипции: H2AK9ac, H2BK120ac, H2BK12ac, H2BK15ac, H3K23ac, H3K4ac, H2BK5ac, H3K18ac, H3K56ac, H4K12ac, H4K8ac и H4K91ac. Такое множество модификаций в единичных эмбриональных клеточных линиях может свидетельствовать о важной роли данного локуса на ранних этапах развития.

Все перечисленные выше модификации гистонов запускают/усиливают/поддерживают транскрипцию. И лишь две из колокализованных с анализируемыми маркерами модификации приводят к транскрипционному сайленсингу – это H3K27me3 [16] и H3K23me2 [17]. Среди изученных маркеров с H3K27me3 колокализован rs189037 в клетках зародышевого матрикса; а с H3K23me2 – rs20579 в эмбриональных стволовых клетках линии H1-hESC. Вероятно, более тонкая регуляция функций этих локусов в эмбриональном развитии может играть важную роль.

Таким образом, с учетом характера модификаций гистонов, колокализованных с привлеченными к анализу SNP генов системой репарации ДНК, можно заключить, что, во-первых, все эти регионы в большинстве изученных тканей активно транскрибируются; во-вторых, два региона

(колоакализованные с rs1805800 и rs189037) участвуют в организации топологических доменов, причем один из них (колоакализованный с rs180937), вероятно, играет важную роль в эмбриональном развитии.

ЗАВИСИМОСТЬ ЭКСПРЕССИОННОГО СТАТУСА ГЕНОВ ОТ АНАЛИЗИРУЕМЫХ ПОЛИМОРФНЫХ ВАРИАНТОВ

Репарация ДНК – один из базовых процессов живой клетки, а экспрессия генов, белковые продукты которых задействованы в его реализации и контроле, идет во всех типах тканей на всех стадиях онтогенеза. Однако, в отличие от генов “домашнего хозяйства”, уровень экспрессии генов, кодирующих белки систем репарации ДНК варьирует в зависимости от потребности клетки; и чем шире сфера компетенции этих генов, тем выше наблюдаемый уровень экспрессии. Для всех рассматриваемых здесь генов минимальный уровень экспрессии составлял от 1–2 TPM (Transcripts Per Million – транскриптов на миллион): *ATM* в скелетных мышцах, *MRE11* в тканях головного мозга, *TP53BP1* в цельной крови, *PMS2* в миокарде, *LIG1* в левом желудочке – до 5–6 TPM (*NBN* в коре почек, *MLH1* в цельной крови) (<https://gtexportal.org/home/>). Интересно, что максимальный уровень этих транскриптов в большинстве случаев детектировали в лимфоцитах, стимулированных вирусом Эпштейна–Барр (*ATM* – 21, *MRE11* – 22, *NBN* – 67, *MLH1* – 48, *PMS2* – 22, *LIG1* – 51 TPM), и только для гена *TP53BP1* максимальный уровень экспрессии регистрировали в гипофизе – 50 TPM (<https://gtexportal.org/home/>). Все вышеперечисленные маркеры (табл. 1) относятся к *cys*-eQTL-вариантам (то есть могут влиять на экспрессию “своего” и расположенных рядом генов) и большая часть – к sQTL-вариантами (влияют на сплайсинг).

В подавляющем большинстве случаев изменение экспрессии подчиняется линейной зависимости: либо RR > RP > PP, либо RR < RP < PP (где R – референсный аллель, P – производный аллель), – поэтому далее мы преимущественно обсудим различия между экспрессией гомозиготных генотипов, подразумевая, что гетерозиготы занимают промежуточное положение. Те случаи, когда наблюдаются отклонения от указанной тенденции, будут рассмотрены особо.

Влияние rs560191 в гене TP53BP1 на экспрессию и сплайсинг

rs560191 (*TP53BP1*) находится в пределах большого блока корегулируемых генов (рис. 2). Уровень сцепления, близкий к единице, выявлен для SNP, расположенных вокруг rs560191 и охватывающих регион больше 87 млн.п.н. Этот блок сцеп-

ления включает маркеры, которые представляют собой eQTL для 20 генов и sQTL для 11 генов (<http://www.mulinlab.org/vportal/index.html>).

Для большинства генов, регулируемых rs560191 (табл. S1, см. Дополнительные материалы на сайте http://www.molecbio.ru/downloads/2023/1/supp_Babushkina_rus.zip), характерно одностороннее изменение экспрессии в различных тканях в зависимости от генотипа. Так, для *AC011330.13* (4 ткани), *AC011330.5* (40 тканей), *ADAL* (37 тканей), *CATSPER2* (1 ткань), *CCNDBP1* (4 ткани), *CKMT1A* (4 ткани), *CKMT1B* (1 ткань), *PDIA3* (3 ткани), *TP53BP1* (15 тканей), *TTBK2* (2 ткани) у гомозиготных носителей анцестрального аллеля (GG) уровень экспрессии выше, чем у гомозигот по производному аллелю (CC), а для гетерозигот характерны промежуточные значения. В то же время обратная ситуация (GG < CC) наблюдается для генов *CATSPER2P1* (14 тканей), *MAP1A* (2 ткани), *RNU6-554P* (1 ткань), *STRC* (27 тканей), *STRCP1* (25 тканей), *TGM7* (3 ткани), *TUBGCP4* (2 ткани). Для трех генов (*LCMT2*, *TGM5*, *ZSCAN29*) отмечается межтканевая вариабельность характера экспрессии. Так, максимальный уровень экспрессии гена *LCMT2* в слизистой оболочке пищевода наблюдается у гомозигот CC, в то время как в четырех других тканях (большеберцовые нервы, культуры фибробластов, семенники, гладкомышечные клетки пищевода) – у гомозигот GG. В трех тканях (в слизистой оболочке и гладкомышечных клетках пищевода, ободочной кишке) характер экспрессии гена *TGM5* изменяется в направлении GG > GC > CC, а в трансформированных вирусом Эпштейна–Барр лимфоцитах – в обратном направлении (GG < GC < CC). Экспрессия гена *ZSCAN29* выше у гомозигот по предковому аллелю в 25 исследованных тканях, кроме тканей мозга (хвостатое и прилежащее ядро базальных ганглиев, фронтальная кора, передняя поясная кора), в которых экспрессия этого гена наиболее выражена у носителей производного аллеля в гомозиготном состоянии (<https://gtexportal.org/home/>).

Показано влияние генотипов rs560191 на сплайсинг 11 генов, из них 10 совпадают с генами, для которых этот полиморфный вариант является eQTL, еще один ген – *PPIP5K1* – не входит в этот список. Данный регион характеризуется сложной регуляцией транскрипции. В частности, происходит образование общего транскрипта при считывании генов *CATSPER2P1*, *AC011330.5*, *CATSPER2*. Для них показаны общие эффекты сплайсинга: производный аллель в дозозависимой манере увеличивает эффективность вырезания интрона 11 гена *CATSPER2*, что оказывает влияние на сплайсинг мРНК генов *AC011330.5* (в 20 тканях) и *CATSPER2* (в 37 тканях). Эффективность вырезания интрона 10 гена *CATSPER2* из общего транскрипта снижается в скелетных мышцах, шейном

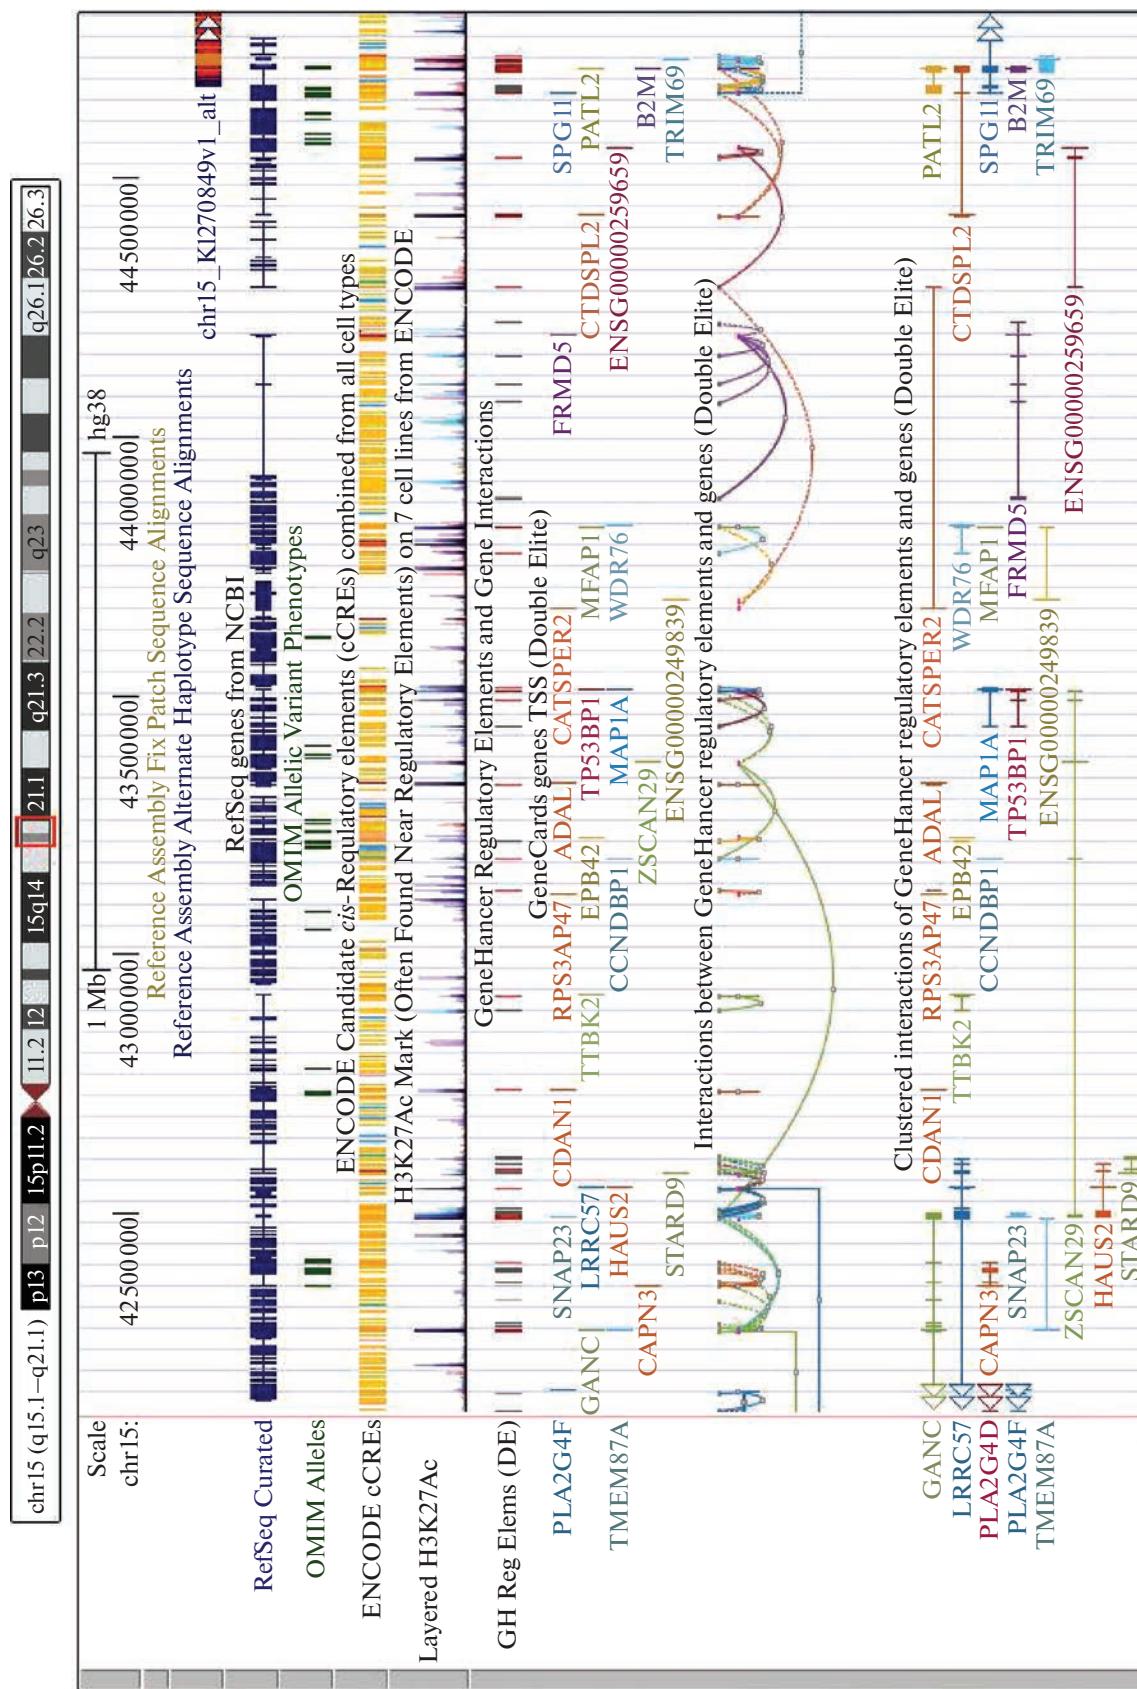


Рис. 2. Взаимодействия между регуляторными элементами и генами (согласно GeneHancer) в регионе локализации гена *TP53BP1*. Разными цветами выделены отдельные гены и их регуляторные взаимодействия (воспроизведено из онлайн-браузера UCSC; <https://genome.ucsc.edu/>).

отделе спинного мозга, мозжечке и черной субстанции головного мозга (оказывая влияние на сплайсинг мРНК гена *CATSPER2*) и повышается в семенниках (влияя на сплайсинг *CATSPER2P1* и *CATSPER2*). Повышение эффективности вырезания области, включающей экзон 1–инtron 4 гена *CATSPER2*, влияет на сплайсинг мРНК гена *AC011330.5* (в мозжечке). Кроме этого, носительство производного аллея rs560191 приводит к снижению эффективности вырезания отдельных инtronов в генах *AC011330.5*, *CATSPER2*, *PPIP5K1*, *STRCP1*, *TGM5*, *TGM7*, *TP53BP1* и *ADAL* (показано в одной–трех тканях для каждого транскрипта).

Повышение эффективности вырезания показано для экзона 2 (с прилегающими инtronами) гена *ADAL* (в 9 тканях), экзона 19 (с прилегающими инtronами) гена *STRC* (в мозжечке), интрана 2 гена *ZSCAN29* (в сигмовидной кишке) (<https://gtexportal.org/home/>).

Соотношение изоформ белка, синтезирующихся в результате альтернативного сплайсинга, зависит в том числе от того, насколько эффективно будет происходить вырезание тех или иных последовательностей из пре-мРНК. В случае, когда зарегистрирована зависимость и уровня экспрессии, и сплайсинга от одного и того же варианта одного и того же гена в одной и той же ткани, можно проанализировать, каким образом меняется синтез зрелой мРНК в зависимости от анализируемой нуклеотидной замены. Можно предположить, что при одностороннем изменении, например при усилении экспрессии в направлении $RR < RP < PP$ и повышении эффективности вырезания какого-либо фрагмента мРНК, общее увеличение продукции гена происходит, главным образом, за счет того/тех вариантов, в которых вырезаемый фрагмент отсутствует. И напротив, если эффективность снижается (в соответствии с примером выше, это $RR > RP > PP$), то усиление экспрессии происходит за счет относительного увеличения частоты тех вариантов, в которых этот фрагмент остается.

Анализ данных по влиянию rs560191 на экспрессию и сплайсинг показывает, что повышение эффективности вырезания интрана 11 гена *CATSPER2* сопряжено со снижением уровня транскрипции генов *CATSPER2* (в слизистой оболочке желудка) и *AC011330.5* (в 21 ткани). Снижение экспрессии *AC011330.5* в мозжечке идет на фоне увеличения эффективности вырезания экзона 1–интрана 4 гена *CATSPER2*, а в семенниках – интрана 25 гена *AC011330.5*. Снижение экспрессии гена *ADAL* происходит на фоне повышения эффективности вырезания экзона 2 с прилегающими инtronами (в 7 тканях) и понижения эффективности вырезания интрана 2 (в гипофизе). Общее снижение экспрессии генов *TGM5* и *TP53BP1* сопряжено со снижением эффективности вырезания их интранов (9 и 23 соответственно). Снижение эффективности вырезания интрана 11 в гене *TGM7* и интрана 24 гена *STRCP1*, а также повышение эффективности вырезания экзона 19 с прилегающими инtronами в гене *STRC* сопряжены с увеличением уровня экспрессии соответствующих генов в отдельных тканях (<https://gtexportal.org/home/>).

Влияние rs1805800 и rs709816 в гене NBN на экспрессию и сплайсинг

Изученные маркеры в гене *NBN* находятся на расстоянии 29 628 п.н.: rs1805800 локализован в регионе рядом с 5'UTR гена *NBN*, rs709816 – в экзоне 10. Вместе с тем, они достаточно тесно сцеплены. Так, для популяции г. Томска значения показателей сцепления: коэффициента неравновесия по сцеплению (D'), логарифма отношения шансов (*LOD-score*) и коэффициента корреляции Пирсона (r^2) – равны соответственно 0.942, 85.11 и 0.712; по данным проекта “1000 Genomes” у европеоидов $D' = 0.995$, $r^2 = 0.846$. Исходя из данных проекта “1000 Genomes” по сцеплению маркеров, SNP, расположенные в пределах региона размером 142 т.п.н., включающего полностью ген *NBN*, сцеплены достаточно тесно (D' в пределах 0.945–1.00) и образуют единый регуляторный блок eQTL- и sQTL-вариантов (<http://www.mulin-lab.org/vportal/index.html>, <https://genome.ucsc.edu/>).

По данным ресурса GTExPortal (<https://gtexportal.org/home/>), указанные нуклеотидные замены относятся к eQTL-вариантам, влияющим на экспрессию как “своего”, так и близкорасположенных генов: *CALB1*, *DECRI*, *OSGIN2* – и, кроме того, на уровень экспрессии гена *RP11-662G23.1*, локализованного более чем в 821 т.п.н. от промотора гена *NBN* (табл. S1, см. Дополнительные материалы на сайте http://www.molecbio.ru/downloads/2023/1/supp_Бабушкина_rus.zip) (<https://gtexportal.org/home/>, <https://genome.ucsc.edu/>).

Для большинства изученных тканей характерно одностороннее изменение экспрессии ряда генов в зависимости от генотипов по rs1805800. Так, при увеличении дозы альтернативного аллеля (T) возрастает уровень экспрессии гена *CALB1* (в 6 из 6 изученных тканей), *NBN* (в 15 из 18 тканей), *OSGIN2* (в трех тканях из четырех изученных). Из общей тенденции есть несколько исключений. Для *RP11-662G23.1* в единственной изученной ткани (мышечной ткани пищевода) отмечается сходная в отношении гомозиготных генотипов тенденция (TT>CC), однако минимальный уровень экспрессии зарегистрирован у носителей гетерозиготного генотипа. Самая высокая экспрессия наблюдается у гомозигот по референсному аллелю в четырех тканях из пяти изученных для гена *DECRI* (за исключением скелет-

ных мышц, в которых наблюдается обратная зависимость). Для гена *NBN* к исключениям относятся цельная кровь и ткань пищеводно-желудочного соединения, в которых наиболее высокий уровень экспрессии детектируют у гомозигот с референсным генотипом (CC), а также кора головного мозга, где, при общей тенденции CC<TT, уровень экспрессии максимален у гетерозигот. Для ткани пищеводно-желудочного соединения показаны также отличия в экспрессии гена *OSGIN2*: у гомозигот по производному аллелю уровень экспрессии ниже, чем по анцестральному (<https://gtexportal.org/home/>).

В зависимости от генотипов по маркеру rs709816 в экзоне 10 гена *NBN* меняется уровень экспрессии тех же генов, хотя характер изменений несколько иной. У гомозигот по альтернативному аллелю (AA) экспрессия гена *NBN* выше в 14 из 14 изученных тканей (как показано и для rs1805800), однако более низкий уровень экспрессии зарегистрирован для генов *CALB1* (в 7 изученных тканях) и *RP11-662G23.1* (в мышечной ткани пищевода). Ген *DECRI* экспрессируется интенсивнее у носителей производного аллеля в четырех изученных тканях, еще в двух (в скелетных мышцах и ушке предсердия) зависимость экспрессии обратная. Уровень экспрессии гена *OSGIN2* в мышечной ткани пищевода выше у гомозигот по альтернативному аллелю, тогда как в цельной крови и ткани пищеводно-желудочного соединения – у гомозигот по референсному аллелю (<https://gtexportal.org/home/>).

Анализируемые маркеры в гене *NBN* относятся к sQTL-вариантам для генов *DECRI* и *NBN*. При процессинге мРНК гена *DECRI* эффективность вырезания интрана 1 выше у носителей производных аллелей обоих изученных маркеров: для генотипа TT rs1805800 в легких и коже, не подвергающейся солнечной экспозиции; для генотипа GG rs709816 – в легких, коже, не подвергающейся солнечной экспозиции, и тканях молочной железы (<https://gtexportal.org/home/>).

Для гена *NBN* отмечено тканезависимое изменение соотношений вариантов сплайсинга в зависимости от генотипов по изученным маркерам. У носителей гомозиготных генотипов обоих исследованных маркеров повышается эффективность вырезания интрана 4 в семенниках, скелетных мышцах, большеберцовых артериях, ткани пищеводно-желудочного соединения, ткани молочной железы и снижается в большеберцовых нервах и в лимфоцитах, трансформированных вирусом Эпштейна–Барр. Аналогично снижается эффективность вырезания интрана 2 в культурах фибробластов и в подкожной жировой клетчатке (<https://gtexportal.org/home/>).

В базах данных для пяти тканей приведена информация по изменениям и уровням экспрессии

гена *NBN*, а также вариантам его сплайсинга (в зависимости от изученных SNP). В отношении обоих маркеров (rs1805800 и rs709816) выявленная изменчивость носит одинаковый характер: в трех тканях носительство альтернативных аллелей приводит к увеличению экспрессии гена в целом при увеличении эффективности вырезания интрана 4 (в семенниках, скелетных мышцах, большеберцовых артериях); в двух тканях общее увеличение уровня экспрессии происходит на фоне снижения эффективности вырезания интрана 4 (в большеберцовых нервах) и интрана 2 (в подкожной жировой клетчатке) (<https://gtexportal.org/home/>).

Влияние rs189037 и rs1801516 в гене ATM на экспрессию и сплайсинг

Исследованные маркеры в гене *ATM* в популяции г. Томска находятся в неравновесии по сцеплению. Так, показатели сцепления для rs189037 и rs1801516 в гене *ATM* следующие: $D' = 0.869$, $LOD = 11.44$, $r^2 = 0.109$. В научных публикациях и базах данных (см., например, Ensemble: <http://www.ensembl.org/index.html>) их сцепление не анализируется ввиду значительной удаленности друг от друга – изученные маркеры rs189037 (промоторный регион) и rs1801516 (экзон 37) находятся на расстоянии 81.5 т.п.н. Тем не менее для каждого из анализируемых SNP идентифицирован обширный регион, маркеры в котором тесно сцеплены и являются eQTL для одних и тех же генов. Для rs189037 размер этого региона не менее 167 т.п.н., для rs1801516 – не менее 192 т.п.н. (<http://www.mulinlab.org/vportal/index.html>).

rs189037 представляет собой eQTL-вариант для “своего” и близлежащих генов: *ACAT1*, *NPAT*, *C11orf65*, *KDELC2* (*POGLUT3*) (табл. S1, см. Дополнительные материалы на сайте http://www.molecbio.ru/downloads/2023/1/supp_Babushkina_rus.zip). В большинстве случаев альтернативный аллель (A) приводит к снижению уровня экспрессии корегулируемых генов. Исключения отмечены в отдельных тканях для генов *NPAT* (в цельной крови) и *ATM* (в щитовидной железе), а также для *C11orf65* в коре надпочечников (единственная ткань, для которой в настоящее время показано влияние rs189037 на уровень экспрессии рассматриваемого гена). Кроме того, для гена *ATM* в трех тканях (ушке предсердия, сальнике и слизистой оболочке пищевода) наименьший уровень экспрессии зарегистрирован у гетерозигот (при сохранении общей тенденции: GG>AA) (<https://gtexportal.org/home/>).

rs1801516 также выступает как eQTL-вариант для “своего” и близлежащих генов: *ACAT1*, *NPAT*, *C11orf65* (табл. S1, см. Дополнительные материалы на сайте http://www.molecbio.ru/downloads/2023/1/supp_Babushkina_rus.zip). У гомозигот по аль-

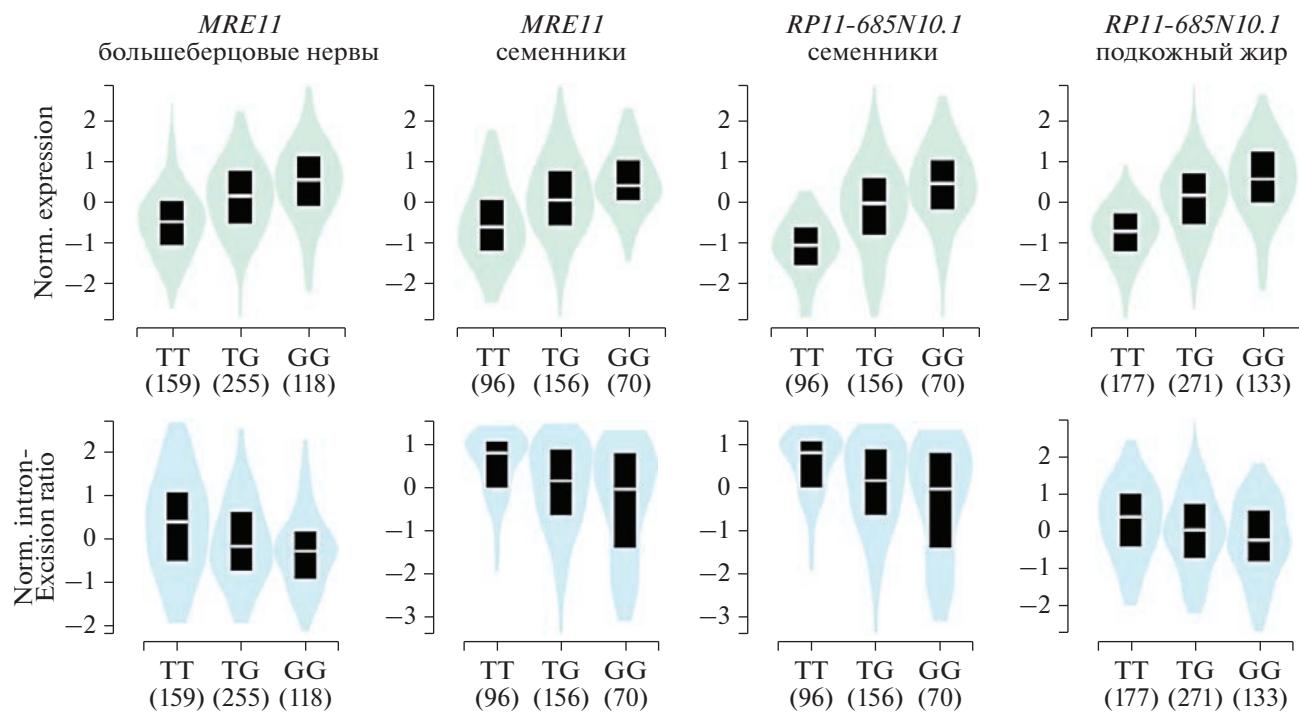


Рис. 3. Изменение уровня экспрессии (вверху) и эффективности сплайсинга (внизу) генов *MRE11* (в большеберцовых нервах и семенниках) и *RP11-685N10.1* (в семенниках и подкожной жировой ткани) в зависимости от rs473297 в гене *MRE11*. Ось X – генотипы по rs473297, ось Y – нормализованные уровни экспрессии (вверху), нормализованный уровень вырезания интрана (по данным GTExPortal: <https://gtexportal.org/home/>).

тернативному аллелю (AA) регистрируют пониженные уровни экспрессии генов *ACAT1* (в щитовидной железе, скелетных мышцах, легких, культурах фибробластов) и *ATM* (мышечная ткань пищевода) и повышенные для генов *NPAT* (большеберцовые нервы и аорта) и *C11orf65* (в гипофизе, щитовидной железе и коже, подвергающейся солнечной экспозиции) (<https://gtexportal.org/home/>).

К sQTL относится только rs189037, причем только для гена *ATM*: в культуре фибробластов происходит дозозависимое снижение эффективности вырезания интрана 40, в то время как в легких, поджелудочной железе и сальнике эффективность вырезания повышается, как и в отношении интрана 26 в большеберцовых нервах (<https://gtexportal.org/home/>).

Для двух тканей можно соотнести eQTL- и sQTL-влияние rs189037 на синтез зрелой мРНК белка ATM. Общее снижение уровня экспрессии гена *ATM* в культуре фибробластов происходит параллельно с увеличением эффективности вырезания интрана 40, а в клетках сальника – на фоне снижения эффективности вырезания этого интрана (<https://gtexportal.org/home/>).

Влияние rs473297 в гене *MRE11* на экспрессию и сплайсинг

rs473297 находится в большом блоке сцепления (не менее 123 т.п.н.), в пределах которого D'

между анализируемым маркером и другими eQTL-SNP составляет 0.95–1.00. rs473297 служит eQTL-вариантом для генов *MRE11* (49 тканей), *GPR83* (4 ткани), *IZUMO1R* (1 ткань) и *RP11-685N10.1* (37 тканей) (табл. S1, см. Дополнительные материалы на сайте http://www.molecbio.ru/downloads/2023/1/supp_Бабушкина_rus.zip). Во всех изученных тканях наличие альтернативного варианта приводит к возрастанию уровня экспрессии генов *IZUMO1R*, *MRE11*, *RP11-685N10.1* и к снижению экспрессии гена *GPR83* (<https://gtexportal.org/home/>). Влияние на уровень сплайсинга показано для генов *MRE11* (семенники и большеберцовые нервы) и *RP11-685N10.1* (8 тканей). Наличие замены приводит к снижению эффективности вырезания интрана 7, внутри которого локализован ген *RP11-685N10.1*. В большеберцовых нервах происходит также снижение эффективности вырезания интрана 1 мРНК гена *MRE11* (рис. 3) (<https://gtexportal.org/home/>).

Влияние rs1799977 в гене *MLH1* на экспрессию и сплайсинг

Для rs1799977 в гене *MLH1* показано полное сцепление (и участие в регуляции одних и тех же генов) с маркерами, находящимися от него на значительном удалении – более 78 т.п.н. в направлении к 3'-концу гена. Тесное сцепление ($D' = 0.912$) показано и с маркером, лежащим на

расстоянии более 80 т.п.н. по направлению к 5'-концу (инtronный вариант гена *TRANK1*); в то же время этот маркер фактически относится к другому регуляторному блоку (<http://www.mulin-lab.org/vportal/index.html>, <https://genome.ucsc.edu/>). По данным проектов ENCODE и GeneHancer, весь этот регион обогащен регуляторными последовательностями, наблюдается значительная ко-регуляция колокализованных генов (<https://genome.ucsc.edu/>, <https://www.genecards.org/>). rs1799977 – eQTL-вариант для десяти и sQTL для трех генов (табл. S1, см. Дополнительные материалы на сайте http://www.molecbio.ru/downloads/2023/1/supp_Бабушкина_rus.zip). Для пяти генов есть информация об изменениях уровней экспрессии в зависимости от данной замены в одной ткани. Показано, что у гомозигот по варианту аллелю уровня экспрессии *MLH1* (в скелетных мышцах), *EPM2AIP1* (в щитовидной железе), *RP11-259K5.2* (в коже, подвергавшейся солнечной экспозиции) повышены, а *ITGA9* (в цельной крови) и *PRADC1P1* (в большеберцовых нервах) снижены. Для гена *RP11-129K12.1* показано снижение уровня экспрессии в трех исследованных тканях (в подкожной жировой клетчатке, сальнике, коже, подвергающейся солнечной экспозиции). Для остальных генов зарегистрирован тканезависимый характер изменения экспрессии. Так, при наличии производного аллеля (G) выявлен более низкий уровень экспрессии генов *RP11-285J16.1* и *UBE2F1* (в коже, подвергающейся солнечной экспозиции), а также *GOLGA4* (в слизистой оболочке пищевода) и *LRRFIP2* (в коже вне зависимости от солнечной экспозиции и в цельной крови). Напротив, у носителей генотипа GG выше уровень экспрессии генов *RP11-285J16.1* и *UBE2F1* (в щитовидной железе), *GOLGA4* (в скелетных мышцах и коже, подвергающейся солнечной экспозиции), *LRRFIP2* (в 14 тканях) (<https://gtexportal.org/home/>).

Влияние rs1799977 на сплайсинг показано для трех генов. В подавляющем большинстве случаев замена приводит к снижению эффективности вырезания инtronов: инtron 12 в гене *MLH1* (в большеберцовых артериях), инtron 1 в *LRRFIP2* (в 31 ткани), инtron 22 в *GOLGA4* (в слизистой оболочке пищевода). Повышение эффективности вырезания показано только для интрана 2 гена *GOLGA4* (в скелетных мышцах) и интрана 1 гена *LRRFIP2* (в левом желудочке) (<https://gtexportal.org/home/>). Несмотря на сходный тип “сплайсингового ответа” на альтернативный аллель, в результате тканеспецифичного изменения характера экспрессии *LRRFIP2* имеет место тканеспецифичное изменение соотношений сплайсинговых вариантов этого гена. Так, на фоне снижения эффективности вырезания интрана 1 из мРНК гена *LRRFIP2* в трех тканях (кожа вне зависимости от солнечной экспозиции и цельная кровь) проис-

ходит снижение экспрессии этого гена, а в 11 тканях – усиление (<https://gtexportal.org/home/>).

Vлияние rs1805321 в гене PMS2 на экспрессию и сплайсинг

rs1805321 в гене *PMS2* находится в блоке сцепления eQTL-SNP, охватывающем не менее 76 т.п.н. Эта замена – eQTL-вариант для 7 генов (табл. S1, см. Дополнительные материалы на сайте http://www.molecbio.ru/downloads/2023/1/supp_Бабушкина_rus.zip). В подавляющем большинстве случаев альтернативный аллель (A) приводит к возрастанию уровня экспрессии. Такой характер изменчивости показан для генов *ANKRD61* (в 6 тканях), *CCZ1B* (в 11 тканях), *EIF2AK1* (в 17 тканях), *PMS2* (в 28 тканях), *SNORA42* (в трех тканях). В ряде тканей уровень экспрессии этих генов носит несколько иной характер: при сохранении общей тенденции (GG<AA) максимальный уровень наблюдается у гетерозигот. Такая зависимость зарегистрирована для гена *ANKRD61* в большеберцовых нервах, для *EIF2AK1* в адипоцитах сальника, для *PMS2* в коже, не подвергавшейся солнечной экспозиции, и в базальных ганглиях головного мозга; для *SNORA42* во фронтальной коре головного мозга. И, напротив, показано снижение экспрессии при наличии производного аллеля для гена *CCZ1* (в 8 тканях). Для гена *RAC1* влияние данной замены выявлено в одной ткани (щитовидная железа), уровень максимальен у гомозигот по референсному аллелю, но минимален у гетерозигот (<https://gtexportal.org/home/>).

Влияние rs1805321 на сплайсинг показано для одного гена – *AIMP2* – в двух тканях: эффективность вырезания интрана 1 при наличии производного аллеля снижается в скелетных мышцах и возрастает в коже, подвергающейся солнечной экспозиции (<https://gtexportal.org/home/>).

Vлияние rs20579 в гене LIG1 на экспрессию и сплайсинг

rs20579 в гене *LIG1* находится внутри региона сцепления eQTL-SNP, охватывающего около 28 т.п.н. Это eQTL-вариант для 6 генов (табл. S1, см. Дополнительные материалы на сайте http://www.molecbio.ru/downloads/2023/1/supp_Бабушкина_rus.zip). Производный аллель приводит к возрастанию уровня экспрессии генов *PLA2G4C* (в 22 тканях), *PLA2G4C-AS1* (в легких), *CTC-453G23.5* (в коже, подвергавшейся солнечной экспозиции). Понижение экспрессии наблюдается для генов *LIG1* (в большеберцовых нервах) и *AC022154.7* (в скелетных мышцах). Тканезависимое изменение уровня экспрессии зарегистрировано для гена *CARD8*: у носителей производного аллеля в путамене (базальные ганглии головного мозга) наблюдается повышение уров-

ня экспрессии, а в прилежащем ядре (базальные ганглии головного мозга), напротив, снижение (<https://gtexportal.org/home/>). Влияния rs20579 на сплайсинг к настоящему времени не показано.

Таким образом, все рассматриваемые маркеры изменяют транскрипцию как своего, так и близлежащих генов, будучи для них cys-QTL-вариантами. Тканезависимый характер изменений может определять различия степени поражения тканей и органов при развитии патологического фенотипа; при этом поражения органов-мишней могут быть обусловлены изменениями (как уровня экспрессии в целом, так и альтернативного сплайсинга) спектра корегулируемых генов. Например, ген *ACAT1*, корегулируемый и колокализованный с геном *ATM* (табл. S1, см. Дополнительные материалы на сайте http://www.molecbio.ru/downloads/2023/1/supp_Бабушкина_rus.zip), кодирует митохондриальную ацетил-КоА-ацетилтрансферазу – один из ключевых ферментов этерефикации холестерина. Следовательно, вовлеченность этого фермента в развитие атеросклероза и его патогенетически значимых признаков логически обоснована; блокаторы этого фермента используются для лечения атеросклероза [18]. Одним из возможных объяснений полученных нами ранее ассоциаций гена *ATM* с липидными показателями у больных ИБС [7] может быть именно изменение уровня экспрессии *ACAT1* (и уже его влияние на развитие патологии) в результате нуклеотидных замен в гене *ATM*.

ИЗМЕНЕНИЯ МОТИВОВ СВЯЗЫВАНИЯ ТРАНСКРИПЦИОННЫХ ФАКТОРОВ, ПРОИСХОДЯЩИЕ В РЕЗУЛЬТАТЕ АНАЛИЗИРУЕМЫХ НУКЛЕОТИДНЫХ ЗАМЕН

В результате изменения нуклеотидной последовательности могут меняться сайты связывания TF, что позволяет определять статус нуклеотидных замен в качестве cys-eQTL-SNP. В настоящее время накоплена обширная информация о взаимодействии хроматина и различных TF. Имеющиеся данные получены как экспериментальным путем (методами иммунопреципитации хроматина, например ChIP-Seq), так и биоинформационическими методами. Существует множество инструментов для биоинформационического анализа, позволяющих выявить в нуклеотидной последовательности вероятные мотивы связывания TF и предсказать, каким образом будет меняться их аффинность в результате всевозможных структурных изменений. Однако следует учитывать, что различные инструменты анализа не всегда дают согласующуюся информацию.

Мы проанализировали изменения мотивов связывания TF с помощью ресурсов HaploReg (<https://pubs.broadinstitute.org/mammals/haploreg/>

<haploreg.php>), PolymPact (<https://regulomedb.org/regulome-search/>), GWAS4D ([http://mulinlab.tmu.edu.cn/gwas4d/gwas4d/gwas4d_server](http://mulinlab.tmu.edu.cn/gwas4d/gwas4d/gwas4d/gwas4d_server)) (рис. 4, круговые диаграммы Венна). Наименьшее число изменяющихся мотивов предсказывает HaploReg (<https://pubs.broadinstitute.org/mammals/haploreg/haploreg.php>). Согласно полученным данным, в результате проанализированных вариантов меняются сайты связывания TF в генах *ATM* (rs189037, rs1801516), *TP53BP1* (rs560191), *NBN* (rs1805800). Ресурс PolymPact не определяет изменений мотивов в результате замены в гене *TP53BP1*, но показывает их наличие в генах *ATM*, *NBN*, *MRE11*, *PMS2* (рис. 4). Согласно GWAS4D, все изученные нуклеотидные замены влияют на аффинность связывания TF с их сайтами. Так, rs560191 в гене *TP53BP1* изменяет только 8 сайтов, а rs189037 в гене *ATM* – 33; всего для 9 изученных SNP меняется 168 мотивов для 99 TF (<https://bcglab.cibio.unith.it/polymact/>, <https://pubs.broadinstitute.org/mammals/haploreg/haploreg.php>, http://mulinlab.tmu.edu.cn/gwas4d/gwas4d/gwas4d_server).

Для перекрывающихся мотивов все алгоритмы дают согласующуюся информацию по изменению аффинности связывания TF при изменении нуклеотидной последовательности, хотя перекрывание полученных списков в целом довольно слабое. Так, и HaploReg, и GWAS4D предсказывают изменения аффинности сайтов связывания MYC (rs1805800 в гене *NBN*), а также CHD2 и RAD21 (rs189037 в гене *ATM*). HaploReg и PolymPact дают согласующиеся результаты по отношению к POU5F1 (rs1805800, ген *NBN*), MYC (rs189037, ген *ATM*) и ARID5B (rs1801516, ген *ATM*). Наибольшее число совпадающих результатов получено между данными GWAS4D и PolymPact: rs1805800 (*NBN*) приводит к изменению сайта связывания BHLHE40; rs709816 (*NBN*) – EGR1 и KLF1; rs473297 (*MRE11*) – RUNX2; rs189037 (*ATM*) – USF2, EGR1, TFAP2A; rs1805321 (*PMS2*) – STAT5A (<https://regulomedb.org/regulome-search/>, <https://pubs.broadinstitute.org/mammals/haploreg/haploreg.php>, http://mulinlab.tmu.edu.cn/gwas4d/gwas4d/gwas4d_server) (рис. 4). Большинство из этих TF экспрессируются с разным уровнем в широком спектре тканей, за исключением TFAP2A, который экспрессируется в тканях пищеварительной системы (малая слюнная железа, слизистая оболочка пищевода), мочевыводящей системы (кора и мозговое вещество почки, мочевой пузырь), репродуктивной системы (семенники, влагалище), коже (вне зависимости от солнечной экспозиции) (<https://genome.ucsc.edu/>, <https://www.encodeproject.org/>).

Чтобы проанализировать, связывание каких TF подтверждено экспериментально, мы привлечь данные ChIP-Seq-анализа из ресурсов JASPAR (<https://jaspar.genereg.net/>) [19], ORegAnno (<http://www.oreganno.org/>) [20], ENCODE (<https://www.encodeproject.org/>

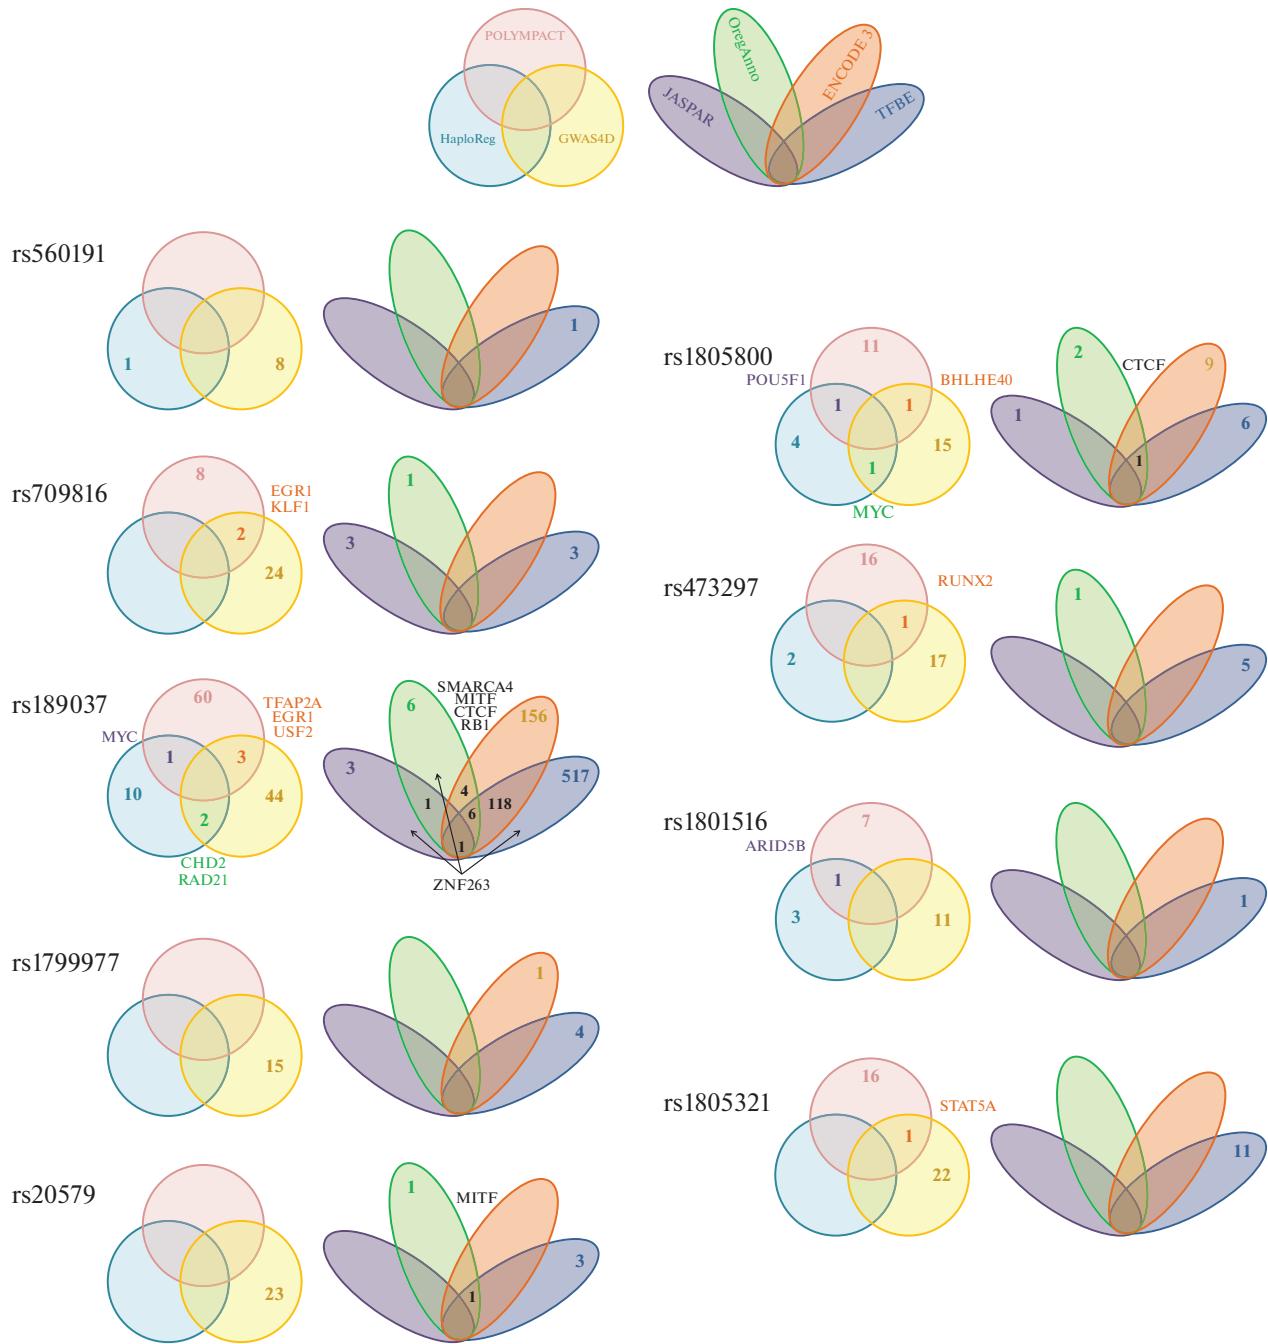


Рис. 4. Влияние изученных SNP-маркеров на сайты связывания транскрипционных факторов. Круговые диаграммы – теоретически рассчитанные мотивы связывания TF с изменяющейся в результате нуклеотидной замены аффинностью (по данным HaploReg, PolyMPACT, GWAS4D). Овальные диаграммы – экспериментально подтвержденные ДНК-белковые взаимодействия в регионах локализации нуклеотидной замены (по данным, приведенным в JASPAR, ORegAnno, ENCODE, VannoPortal). Цифрами указано число мотивов в разных базах данных; названия совпадающих по данным различных ресурсов TF приведены рядом.

encodeproject.org/) [21], а также VannoPortal (<http://www.mulinlab.org/vportal/index.html>), на котором представлены объединенные данные CistromeDB 20181120, DeepBlueR V1.0, GTRD 2020-06, EpiMap 2021-01-11, включающие информацию о связывании TF и других взаимодействующих с

хроматином белков [22–24] (рис. 4, овальные диаграммы Венна).

На основании данных по иммунопреципитации хроматина можно сделать вывод, что регионы локализации анализируемых SNP в кодирующей последовательности минимально связаны с TF.

Так, по данным JASPAR, ORegAnno и ENCODE, не обнаружено сайтов связывания TF для rs560191 в гене *TP53BP1*, rs1801516 в гене *ATM*, rs1805321 в гене *PMS2*. Однако по данным Vanno-Portal, для этих нуклеотидных последовательностей показано связывание в отдельных тканях/клеточных линиях с TF либо иными белками: модификаторами хроматина, ферментативными комплексами и другими, также влияющими на уровень экспрессии белков. Например, в регионе локализации rs560191 выявлено связывание лизиновой метилтрансферазы KMT2A (в клеточной линии RS4 острого лимфобластного лейкоза) и POLR2A – субъединицы A РНК-полимеразы II (в клетках влагалища); с регионом локализации rs1801516 в гене *ATM* связывается BRD4 (в клетках крови); в области гена *PMS2*, содержащей rs1805321, обнаружено связывание 13 белков (каждый в 1–3 типах клеток). В регионах еще двух SNP в кодирующей последовательности одного маркера в 5'UTR факты связывания с единичными TF зарегистрированы в нескольких базах данных, но эти результаты не перекрываются. Так, с регионом локализации rs1799977 в гене *MLH1* по данным ENCODE связывается CTCF (в клетках аденомы парашитовидной железы), по данным VannoPortal – FOXA1 (в клетках простаты), SPIB (в костном мозге), GATA4 и FOXA2 (в коже). С регионом локализации rs709816 в гене *NBN* связывается ряд белков: ZSCAN4, CEBPD, CEBPA (JASPAR); E2F1 (ORegAnno); AR, MYC, POLR2A, BRD4 (VannoPortal). Область локализации rs473297 в гене *MRE11* совпадает с сайтом связывания SMARCA4 (ORegAnno); ARID1A, FOXA2, GATA3, GATA4, GATA6 (VannoPortal) (<http://www.mulinlab.org/vportal/index.html>, <https://www.encodeproject.org/>, <https://jaspar.genereg.net/>, <http://www.oreganno.org/>).

Только для трех изученных маркеров (5'UTR генов *NBN*, *LIG1*, *ATM*) списки связываемых с областью их локализации белков частично пересекаются (рис. 4). Для rs1805800 выявлено связывание нуклеотидной последовательности с TFEB (JASPAR); SMARCA4 и CTCF (ORegAnno); CTCF (в 150 тканях), H2AZ, EP300, SNAI2, SMC3, NR3C1 (VannoPortal); CTCF (в 187 тканях) и еще 8 TF (в 1–5 тканях) (ENCODE). Таким образом, в трех из проанализированных ресурсов содержится информация о связывании этой нуклеотидной последовательности с транскрипционным репрессором CTCF. В регионе rs20579 (в гене *LIG1*) зарегистрировано связывание MITF (ORegAnno); H2AZ, MITF, FOXP1 (VannoPortal). В двух базах в этом регионе зарегистрировано связывание MITF.

Наибольшее число ДНК-белковых взаимодействий зарегистрировано для региона, в котором находится rs189037 (ген *ATM*). В ресурсе JASPAR для этой области показано взаимодействие с факторами ZNF263, SP5 и ZNF148. Согласно ORegAnno,

ДНК в этом регионе ассоциирована с SMARCA4, RBL2, RB1, ZNF263, CTCF и MITF. С этой областью взаимодействует 156 TF по данным ENCODE, 517 – по данным VannoPortal; для двух последних ресурсов 118 белков общие. В списках сразу трех ресурсов встречаются SMARCA4, RB1, CTCF, MITF (ORegAnno, ENCODE, VannoPortal) и ZNF263 (ORegAnno, JASPER, VannoPortal); из них к TF, связываемым в широком спектре тканей, относится только CTCF (рис. 4).

Как можно заметить, для двух промоторных регионов (rs1805800 и rs189037) характерно связывание с CTCF. Это CCCTC-связывающий фактор, играющий важную мультифункциональную роль в ремоделировании хроматина [12, 25]. Хорошо известна роль CTCF в связывании инсуляторных последовательностей, поэтому можно предположить, что именно эта функция CTCF наиболее значима в данных локусах.

В то время как результаты, полученные с помощью методов биоинформационического анализа, указывают на наличие возможности связывания с ДНК определенных TF, методы иммунопреципитации хроматина показывают реально существующие связи, но в отдельных клетках/тканях на определенной стадии развития, в определенном физиологическом состоянии и с определенной нуклеотидной последовательностью. В связи с этим отсутствие экспериментального подтверждения теоретических расчетов нельзя рассматривать как доказательство отсутствия такого взаимодействия в принципе – просто оно не зарегистрировано в проанализированных биообразцах. Мы сопоставили результаты биоинформационического анализа и данные ChIP-seq для исследованных маркеров. Только для rs189037 выявлено совпадение TF и других белков хроматина, аффинность которых к сайтам связывания теоретически изменяется в результате нуклеотидной замены и связывание которых с этим регионом имеет экспериментальное подтверждение. Для аннотированных в базе JASPAR TF не выявлено изменений аффинности к мотивам связывания, а для ряда TF, аннотированных в трех других базах, такие мотивы идентифицированы (табл. 3).

Экспериментально выявляемые регионы ДНК-белковых взаимодействий достаточно протяженны (среди проанализированных их длина составила 152–1975 п.н.). Длина рассчитанных теоретически мотивов значительно короче (8–20 п.н.). Для всех потенциально изменяющихся мотивов подтверждена их локализация внутри региона взаимодействия (на рис. 5 в качестве примера приведены данные для мотивов четырех TF). Таким образом, нуклеотидная замена в ДНК может приводить к изменению аффинности связывания соответствующих TF и тем самым определять эффективность их функционирования. Кроме того,

Таблица 3. Экспериментально подтвержденные ДНК-белковые взаимодействия, для которых теоретически предсказано изменение аффинности связывания транскрипционных факторов с их сайтами в результате нуклеотидной замены rs189037

Биоинформатический ресурс	Ресурсы с данными иммунопреципитации хроматина ^a			
	JASPAR	ORegAnno	ENCODE	VannoPortal
HaploReg	0	0	4 MYC ↑ RAD21 ~	5 MYC ↑ RAD21 ~ ELF1 ↓ ZNF143 ↓
GWAS4D	0	1 CTFC ↑	17 CTCF ↑ RAD21 ↑	26 CTCF ↑ RAD21 ↑ SMC3 ↑ GABPA ↑ NRF1 ↑ HDAC2 ↓ SIN3A ↑ CDK8 ↑ USF1 ↑
Polymapct	0	0	9 MYC ↑	22 MYC ↑ REST ↑ E2F1 ↓ (7 сайтов) TRIM28 ↓ USF1 ↑ (6 сайтов)

^a Указано число TF, общих для разных ресурсов; приведены названия только тех TF, наличие которых в данной точке зарегистрировано более чем в 10 тканях. Стрелками ↑ и ↓ указано соответственно увеличение и снижение аффинности TF к мотиву при наличии альтернативного аллеля; знак “~” указывает на незначительное изменение (по биоинформатическим данным). Отдельные мотивы в пределах одного региона в различных ресурсах могут быть сдвинуты вправо или влево относительно друг друга.

при наличии альтернативного аллеля биоинформационные ресурсы предсказывают появление *de novo* сайтов связывания TF, предполагающих появление новых регуляторных контуров. Появление таких сайтов предсказано для всех изученных SNP. Непонятно, реализуется ли эта возможность, но с учетом тканеспецифичности широкого спектра TF можно определить, какие ткани могут быть мишениями в этом случае.

Таким образом, разнообразие изменяемых мотивов связывания TF может объяснить роль исследованных SNP в качестве QTL-вариантов. Так, например, с регионом локализации rs189037 (в гене *ATM*) связывается фактор USF1 (<http://www.mulinlab.org/vportal/index.html>), регулирующий экспрессию широкого спектра генов метаболизма липидов и глюкозы [26, 27]. В литературе описана мутация в гене *USF1*, приводящая к семейной гиперлипидемии [28], из чего можно сделать вывод о его важной роли в детерминации уровня

липидов. rs1189037 меняет аффинность связывания USF1. Так, согласно ресурсу GWAS4D, при наличии альтернативного аллеля появляется новый, ранее не существовавший мотив связывания этого TF с локализацией 11:108093828–108093837; согласно ресурсу Polymapct, увеличивается аффинность пяти вероятных мотивов и появляется один новый (с точкой старта в 11:108093826). Таким образом, при наличии альтернативного аллеля сродство TF к последовательности ДНК усиливается, что может влиять на эффективность его функционирования. Следовательно, этот путь может быть еще одним механизмом, объясняющим ассоциированность rs1189037 с липидными показателями у больных ИБС [7]. Вместе с тем вышеупомянутая информация указывает на то, что рассматриваемые маркеры при ассоциативных исследованиях могут отражать участие в патологическом процессе не только “своего” гена, но и тех, в регуляции функционирования которых они принимают участие.

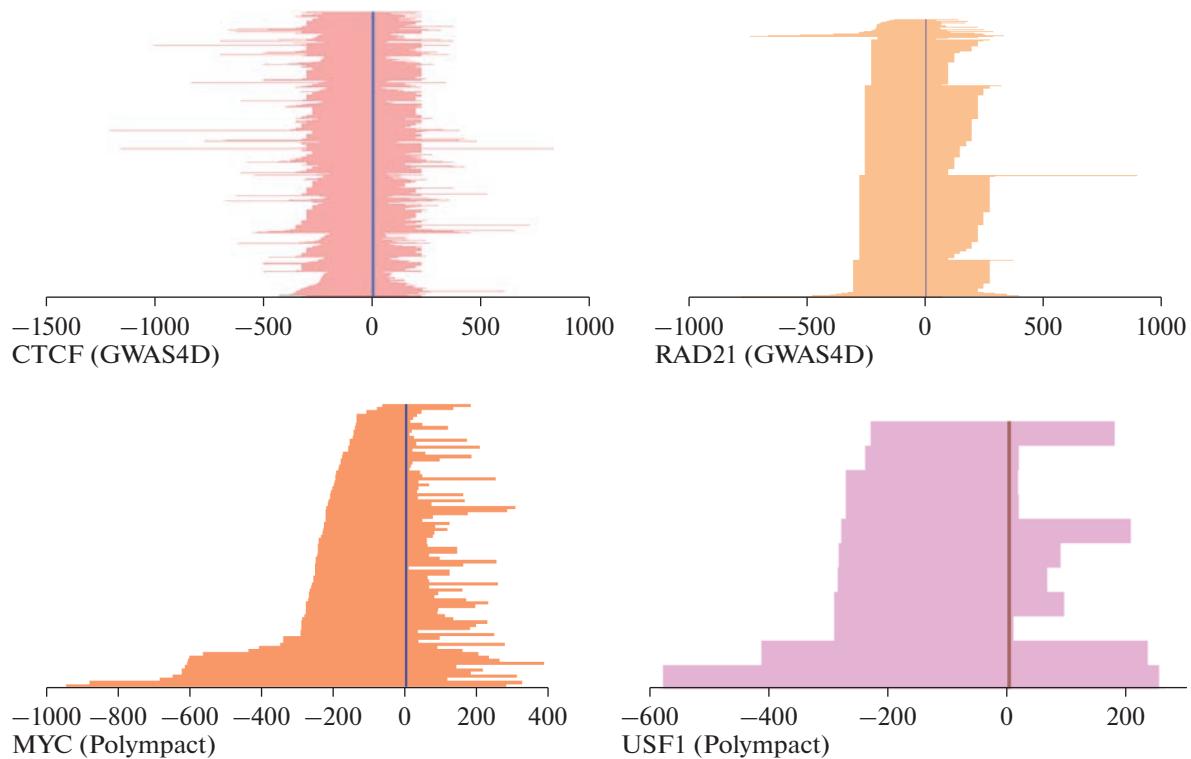


Рис. 5. Локализация изменяемых мотивов связывания транскрипционных факторов в регионах иммунопреципитации соответствующих белков в различных тканях (составлено по данным Polymapct и VannoPortal). Вертикальная полоса представляет собой теоретически рассчитанный изменяемый мотив, цветные горизонтальные полосы – экспериментально выявленные регионы ДНК-белковых взаимодействий в различных тканях. Ось X представляет собой длину мотивов связывания TF (в нуклеотидах); за нулевую отметку принято положение теоретически рассчитанного изменяемого мотива. Ось Y – ткани, в которых с помощью иммунопреципитации хроматина показано связывание этих TF (число тканей составляет 1457, 912, 89 и 11 для CTCF, RAD21, MYC и USF1 соответственно).

АДАПТОГЕННЫЙ И ПАТОЛОГИЧЕСКИЙ ПОТЕНЦИАЛ АНАЛИЗИРУЕМЫХ ПОЛИМОРФНЫХ ВАРИАНТОВ

Межвидовые сравнения свидетельствуют о высоком уровне консервативности четырех из девяти проанализированных локусов. В первую очередь это касается SNP в кодирующем регионе гена *ATM* – rs1801516, для которого консервативность у позвоночных определена с помощью всех анализируемых алгоритмов (табл. 4). Немногим ниже уровень консервативности rs1799977 – замены в кодирующем регионе гена *MLH1*: методом PhyloP (измеряет эволюционную консервативность отдельных последовательностей ДНК) выявлена высокая консервативность у млекопитающих и позвоночных в целом, но не у приматов. Методами PhastCons, GERP⁺⁺ консервативность этого локуса на разных эволюционных уровнях подтверждена (табл. 4). Можно предположить, что данный регион в ходе эволюционной истории стал изменяться именно у приматов.

Несколько менее выражена консервативность промоторной последовательности гена *ATM* – для rs189037 устойчивое сохранение последова-

тельности выявлено с помощью анализов PhyloP и GERP⁺⁺, но не PhastCons (определяющего вероятность того, что каждый нуклеотид принадлежит консервативному элементу) (табл. 4). Напротив, для rs560191 в гене *TP53BP1* консервативность определена методом PhastCons на различных уровнях, но PhyloP подтверждает ее наличие только у приматов, а оценки GERP⁺⁺ – наличие высокой гомологии у разных видов (табл. 4). Статистика GerpN (оценывающая сохранение последовательности у видов) определяет как консервативные наибольшее число проанализированных локусов (rs560191, rs709816, rs189037, rs1801516, rs1799977, rs1805321), причем только этот метод считает “вероятно консервативными” rs709816 (в гене *NBN*) и rs1805321 (в гене *PMS2*) (табл. 4). Согласно всем видам анализа, к консервативным не относятся промоторные регионы генов *NBN* (rs1805800), *MRE11* (rs473297) и *LIG1* (rs20579).

Не все полученные оценки хорошо согласуются между собой. Так, показано, что 7 из 9 изученных SNP оказывают выраженное влияние на приспособленность (согласно оценкам пригодности FitCons), в том числе и “высоконейтральный” rs20579. В то же время локус rs473297, находящий-

Таблица 4. Эволюционная роль изученных полиморфных вариантов генов, кодирующих белки систем репарации ДНК

Способ оценки ^a	Score/Phred Score ^b								
	rs560191	rs1805800	rs709816	rs189037	rs1801516	rs473297	rs1799977	rs1805321	rs20579
verPhyloP	0.38/5.87	-0.20/1.38	-0.16/1.50	1.66/14.75	4.82/27.54	-0.63/0.64	2.59/19.80	-0.01/2.003	-1.36/0.18
mamPhyloP	0.39/6.28	-0.21/1.45	-0.18/1.51	1.19/12.37	2.75/28.23	-0.64/0.69	2.21/20.12	0.39/6.23	-1.66/0.12
priPhyloP	0.65/14.49	-0.27/1.17	-0.28/1.14	0.65/16.10	0.59/13.11	-2.45/0.03	0.53/8.76	-0.15/1.40	-0.90/0.35
verPastCons	0.99/16.76	0.001/1.50	0.01/3.94	0.04/5.42	1/17.61	0/0	1/17.61	0/0	0.002/2.21
mamPastCons	0.99/17.75	0.001/1.57	0.001/1.57	0.05/6.40	1/18.75	0/0	1/18.75	0.01/3.51	0.001/1.57
priPastCons	0.98/19.14	0.03/3.21	0.002/0.51	0.04/3.65	0.97/17.83	0.01/1.54	0.10/23.77	0.004/0.89	0.10/5.27
GerpN	5.9/25.29	2.35/3.82	5.45/17.31	4.97/13.76	5.52/18.00	3.06/5.51	5.76/21.23	5.84/22.77	4.12/9.69
GerpS	1.95/9.59	-0.79/1.21	-1.6/0.74	4.04/17.01	5.52/23.88	-2.58/0.44	4.61/19.16	0.57/5.32	-7.72/0.02
FitCons	0.70/23.33	0.17/15.34	0.72/27.76	0.09/8.40	0.72/27.76	0.09/8.42	0.72/27.76	0.70/23.34	0.36/18.87
bStatistic	6/0.01	526/0.60	528/0.60	130/0.06	115/0.05	635/0.96	154/0.08	725/1.44	743/1.56

^a Показатели PhyloP и PastCons оценивают эволюционную консервативность на основании межвидовых сравнений, за исключением человека (приставки обозначают классификационные ранги: ver – позвоночные, mam – млекопитающие, pri – приматы). Балл PhyloP соответствует $-\lg p\text{-value}$ нулевой гипотезы нейтральной эволюции; положительные значения (до 3) указывают на очищающий отбор, а отрицательные значения (до -14) свидетельствуют об ускоренной эволюции консервативных (и, следовательно, вероятно функциональных) элементов [29, 30]. Показатели PhastCons оценивают вероятность того, что локус содержится в консервативном элементе, варьируют от 0 до 1 и отражают вероятность отрицательного отбора [30–32]. Оценки GerpN и GerpS основаны на анализе отдельных нуклеотидов: высокое значение GerpN указывает на высокую гомологию локуса у разных видов; положительные значения GerpS – на дефицит замен, отрицательные – на их избыточность – и оценивают уровень “ненейтральности” локуса [30, 33]. FitCons оценивает вероятность того, что нуклеотид в данном положении влияет на приспособленность (на основании метода INSIGHT); показатель варьирует от 0 до 1 [34]. bStatistic – оценка фонового отбора, указывающая на ожидаемую долю нейтрального разнообразия, присущего на соответствующем участке: значения, близкие к 0, означают почти полное удаление разнообразия в результате отбора; значения, близкие к 1, указывают на незначительный эффект отбора на разнообразие.

^b Score – оценка, полученная для каждого варианта с помощью использованного алгоритма; Phred Score – показатель качества полученной оценки (значение ≥ 20 соответствует вероятности ошибки 1%). Цифры в светло-серой заливке отображают вероятно консервативные точки генома; в темно-серой заливке – высокое влияние на приспособленность; светло-серая заливка с жирным шрифтом указывает на сильный фоновый отбор, темно-серая с белым шрифтом – локус находится под положительным отбором, черная – локус высоконейтрален.

ся под действием позитивного отбора (то есть замена в этом локусе, вероятно, имеет некоторые адаптивные преимущества), оценки FitCons определяют как не оказывающий влияния на приспособленность. Интересно, что действие фонового отбора зарегистрировано для четырех локусов: обеих замен в гене *ATM* и несинонимичных замен в генах *TP53BP1* и *MLH1* (табл. 4). Фоновый отбор показывает воздействие не на сами анализируемые локусы, а на тесно сцепленные с ними, то есть консервативность этих регионов может быть связана не столько (или не исключительно) с важной ролью именно анализируемых последовательностей, но и быть следствием сцепления. В пользу этого свидетельствует тот факт, что почти во всех генах, в которых локализованы рассматриваемые SNP, описаны мутации, приводящие к моногенным заболеваниям (за исключением *TP53BP1*). Это такие патологии, как атаксия-телеangiэктазия и сходное с ней заболевание (Ataxia-telangiectasia-like disorder 1 – заболевание, подобное атаксии-телеangiэктазии, типа 1), вы-

зываемые мутациями в генах *ATM* и *MRE11* соответственно; синдром хромосомных поломок Ний-меген (мутации в гене *NBN*); синдром Линча и синдром Туркота (причина которых – мутации и в *MLH1*, и в *PMS2*), синдром Мюир–Торре (мутации в гене *MLH1*); аутосомно-рецессивный иммунодефицит-96 (мутации в *LIG4*) (<https://www.ncbi.nlm.nih.gov/omim/?term>).

С позиций “менделевского кода” полиморфные варианты в генах менделевских заболеваний могут оказаться значимыми для многофакторных патологий, в которых задействованы те же биохимические пути. Замечено, что по результатам полногеномных ассоциативных исследований наиболее значимые ассоциации нередко выявляются с маркерами, локализованными вблизи генов менделевских заболеваний, причем наблюдается некоторое перекрывание фенотипических проявлений изучаемых моногенных и сложнонаследуемых заболеваний [35]. Считается, что до четверти генов, мутации в которых приводят к менделевским заболеваниям, ассо-

Таблица 5. Оценка патогенности несинонимичных нуклеотидных замен^a

Инструмент	rs560191	rs1801516	rs1799977	rs1805321
SIFT	Tolerated	Tolerated	Tolerated	Tolerated
SIFT4G	Tolerated	Tolerated	Tolerated	Tolerated
Polyphen2_HDIV		Benign	Benign	Benign
Polyphen2_HVAR	Benign	Benign	Benign	Benign
LRT	Neutral	Deleterious	Deleterious	Neutral
MutationTaster	Polymorphism automatic	Polymorphism automatic	Polymorphism automatic	Polymorphism automatic
MutationAssessor		Low	Low	Low
FATHMM	Tolerated			Tolerated
MetaSVM	Tolerated	Tolerated	Tolerated	Tolerated
MetaLR	Tolerated	Tolerated	Tolerated	Tolerated
PrimateAI	Tolerated	Tolerated	Tolerated	Tolerated
DEOGEN2	Tolerated	Tolerated	Tolerated	Tolerated
BayesDel_addAF	Tolerated	Tolerated	Tolerated	Tolerated
BayesDel_noAF	Tolerated	Tolerated	Tolerated	Tolerated
ClinPred	Tolerated	Tolerated	Tolerated	Tolerated
LIST-S2	Tolerated	Tolerated	Damaging	Tolerated

^a Представлены данные по статусу патогенности миссенс-вариантов, полученные с помощью различных алгоритмов оценки, аккумулированные в dbNSFP (составлено по данным VannoPortal, <http://www.mulinlab.org/vportal/index.html>). В зависимости от алгоритмов и решаемых с их помощью задач статус патогенности оценивали в разных терминах. В таблице сохранена исходная терминология: к благоприятным вариантам относятся Tolerated, Benign, Neutral, Polymorphism automatic, Low; к неблагоприятным – Deleterious, Damaging.

цировано и с многофакторной патологией [36]. С этой точки зрения изучаемые маркеры перспективны для ассоциативного анализа широкого спектра патологий.

Оценки патогенности исследованных SNP неоднозначны. С одной стороны, данные по оценкам патогенности несинонимичных вариантов, полученные на основании широкого спектра наиболее часто используемых алгоритмов, подтверждают отсутствие патологически значимых нарушений белковых молекул вследствие указанных нуклеотидных замен (табл. 5). С другой стороны, геномная оценка патогенности (по regBase [37]) указывает на вероятность вовлеченности в патологические процессы всех анализируемых вариантов (табл. 6). В наибольшей степени это касается SNP в генах *ATM* (rs189037 в 5'UTR, rs1801516 в экзоне 37) и *MLH1* (rs1799977 в экзоне 8). Можно предположить, что геномные оценки патогенности отображают вероятность вовлеченности маркера в развитие многофакторной патологии. Оценки онкогенности также указывают на вероятность “драйверного” эффекта (likely cancer driver) данных нуклеотидных замен для развития онкопатологии (табл. 6).

Следует отметить, что вовлеченность данных маркеров в развитие многофакторной патологии в литературе обсуждается мало. Так, в базе DisGeNet

(<https://www.disgenet.org/>) отсутствует информация относительно rs1805800, rs473297, rs1805321 в контексте привлечения их к ассоциативному анализу при любых патологиях. Только с точки зрения вовлеченности в развитие онкопатологии и/или ее осложнений изучают rs560191, rs709816, rs1801516 и rs20579. Преимущественно при онкопатологии изучают также rs189037 и rs1799977, хотя анализировали вовлеченность rs1799977 в развитие язвенного колита [38, 39], rs189037 – в развитие сердечно-сосудистой патологии, азооспермии, когнитивных нарушений [40–43]. В отношении всех рассматриваемых маркеров результаты ассоциативных исследований противоречивы, в некоторых случаях обсуждается вероятность этноспецифических особенностей ассоциаций (<https://www.disgenet.org/>).

Таким образом, всесторонний анализ изучаемых локусов дает большой объем дополнительной информации, которая может быть полезной для объяснения результатов ассоциативных исследований и более адекватной оценки патологического и адаптогенного потенциала изучаемых локусов. Результаты проведенного анализа указывают на высокий регуляторный потенциал рассматриваемых локусов. Так, показано, что большинство из них находится в составе крупных блоков сцепления QTL-SNP, оказывающих влияние на уровни экспрессии широкого спектра генов

Таблица 6. Геномная оценка патогенности и онкогенности нуклеотидных замен^a

Инструмент	rs560191	rs1805800	rs709816	rs189037	rs1801516	rs473297	rs1799977	rs1805321	rs20579
	Геномная оценка патогенности								
regBase_PAT									
CADD									
DANN									
FATHMM-MKL									
Eigen									
Eigen_PC									
GenoCanyon									
ReMM									
LINSIGHT									
fitCons									
CDTS									
Геномная оценка онкогенности									
regBase_CAN									
FunSeq2									
CScape									

^a Суммированы данные по геномной оценке патогенности и онкогенности, полученные с помощью различных часто используемых алгоритмов оценки некодирующих вариантов, заархивированных в базе данных regBase (RegBase_PAT и RegBase_CAN) [24, 37]. Составлено на основании информации в VannoPortal (<http://www.mulinlab.org/vportal/index.html>). Светло-серые блоки – оценка “вероятно патогенный”, темно-серые – “вероятный фактор развития рака”.

(например, rs560191 является eQTL для 20 генов), а влияние этих замен может оказаться не только на изменении генной экспрессии в целом, но и на сплайсинге. Выявлен возможный эффект варианта rs189037 на усиление топологической роли включающего его хромосомного региона. Показано, что рассматриваемые маркеры при ассоциативных исследованиях могут отражать участие в патологическом процессе не только “своего” гена, но и тех генов, в регуляции которых они принимают участие.

Работа выполнена при частичном финансировании Госзадания Министерства науки и высшего образования (№ 122020300041-7).

Этические нормы соблюдены. Обзор написан с использованием открытых публикаций.

Авторы заявляют об отсутствии конфликта интересов.

СПИСОК ЛИТЕРАТУРЫ

- Zhang F., Lupski J.R. (2015) Non-coding genetic variants in human disease. *Hum. Mol. Genet.* **24**(R1), R102–R110.
<https://doi.org/10.1093/hmg/ddv259>
- Бабушкина Н.П., Постригань А.Е., Кучер А.Н. (2021) Вовлеченность генов белков BRCA1-ассоцированного комплекса наблюдения за геномом (BASC) в развитие многофакторной патологии. *Молекуляр. биология*. **55**(2), 318–337.
<https://doi.org/10.31857/S0026898421020038>
- Бабушкина Н.П., Постригань А.Е., Кучер А.Н. (2018) Вовлеченность генов систем репарации ДНК в развитие сердечно-сосудистой патологии. Сб.: *Молекулярно-биологические технологии в медицинской практике*. Ред. А.Б. Масленников. Новосибирск: Академиздат, с. 48–62.
- Бабушкина Н.П., Постригань А.Е., Хитринская Е.Ю., Кучер А.Н. (2019) Средовые эффекты на ассоциации генов белков систем репарации ДНК с бронхиальной астмой. *VII Съезд Вавиловского общества генетиков и селекционеров (ВОГиС) (2019)*, Санкт-Петербург, Россия. Сборник тезисов, с. 788.
- Бабушкина Н.П., Постригань А.Е., Хитринская Е.Ю., Кучер А.Н. (2019) Вовлеченность полиморфных вариантов генов систем репарации ДНК в развитие многофакторных заболеваний. Сб.: *Генетика человека и патология: актуальные проблемы клинической и молекулярной цитогенетики*. Ред. В.А. Степанов. Томск: Литературное бюро, с. 5–6.
- Бабушкина Н.П., Постригань А.Е., Кучер А.Н. (2020) Гены белков репарации ДНК и продолжительности жизни. *Медицинская генетика*. **19**(5), 99–100.
<https://doi.org/10.25557/2073-7998.2020.05.99-100>

7. Бабушкина Н.П., Постригань А.Е., Кучер А.Н., Кужелева Е.А., Гарганеева А.А. (2020) Ассоциации полиморфизма генов систем репарации ДНК с показателями липидного обмена. *Кардиология 2020 – новые вызовы и новые решения*, Казань. Сборник тезисов, с. 811.
8. Постригань А.Е., Бабушкина Н.П., Кучер А.Н. (2020) Вовлеченность полиморфизма гена *NBN* в формирование предрасположенности к дистропным заболеваниям. *Медицинская генетика*. **19**(8), 98–99. <https://doi.org/10.25557/2073-7998.2020.08.98-99>
9. Peakall R., Smouse P.E. (2012) GenAIEx 6: genetic analysis in Excel. Population genetic software for teaching and research – an update. *Bioinformatics*. **28**(19), 2537–2539. <https://doi.org/10.1093/bioinformatics/bts460>
10. Taverna S.D., Li H., Ruthenburg A.J., Allis C.D., Patel D.J. (2007) How chromatin-binding modules interpret histone modifications: lessons from professional pocket pickers. *Nat. Struct. Mol. Biol.* **14**(11), 1025–1040. <https://doi.org/10.1038/nsmb1338>
11. Hoon D.S.B., Rahimzadeh N., Bustos M.A. (2021) EpiMap: fine-tuning integrative epigenomics maps to understand complex human regulatory genomic circuitry. *Signal. Transduct. Target Ther.* **6**(1), 179. <https://doi.org/10.1038/s41392-021-00620-5>
12. Fu Y., Sinha M., Peterson C.L., Weng Z. (2008) The insulator binding protein CTCF positions 20 nucleosomes around its binding sites across the human genome. *PLoS Genet.* **4**(7), e1000138. <https://doi.org/10.1371/journal.pgen.1000138>
13. Rubio E.D., Reiss D.J., Welcsh P.L., Disteche C.M., Filippova G.N., Baliga N.S., Aebersold R., Ranish J.A., Krumm A. (2008) CTCF physically links cohesin to chromatin. *Proc. Natl. Acad. Sci. USA*. **105**(24), 8309–8314. <https://doi.org/10.1073/pnas.0801273105>
14. Mishiro T., Ishihara K., Hino S., Tsutsumi S., Aburatani H., Shirahige K., Kinoshita Y., Nakao M. (2009) Architectural roles of multiple chromatin insulators at the human apolipoprotein gene cluster. *EMBO J.* **28**(9), 1234–1245. <https://doi.org/10.1038/emboj.2009.81>
15. Shoaib M., Chen Q., Shi X., Nair N., Prasanna C., Yang R., Walter D., Frederiksen K.S., Einarsson H., Svensson J.P., Liu C.F., Ekwall K., Lerdrup M., Nordenskiöld L., Sørensen C.S. (2021) Histone H4 lysine 20 mono-methylation directly facilitates chromatin openness and promotes transcription of housekeeping genes. *Nat. Commun.* **12**(1), 4800. <https://doi.org/10.1038/s41467-021-25051-2>
16. Hansen K.H., Bracken A.P., Pasini D., Dietrich N., Gehani S.S., Monrad A., Rappsilber J., Lerdrup M., Helin K. (2008) A model for transmission of the H3K27me3 epigenetic mark. *Nat. Cell Biol.* **10**(11), 1291–1300. <https://doi.org/10.1038/ncb1787>
17. Vandamme J., Sidoli S., Mariani L., Friis C., Christensen J., Helin K., Jensen O.N., Salcini A.E. (2015) H3K23me2 is a new heterochromatic mark in *Caenorhabditis elegans*. *Nucleic Acids Res.* **43**(20), 9694–9710. <https://doi.org/10.1093/nar/gkv1063>
18. Yang W., Bai Y., Xiong Y., Zhang J., Chen S., Zheng X., Meng X., Li L., Wang J., Xu C., Yan C., Wang L., Chang C.C., Chang T.Y., Zhang T., Zhou P., Song B.L., Liu W., Sun S.C., Liu X., Li B.L., Xu C. (2016) Potentiating the antitumour response of CD8⁺ T cells by modulating cholesterol metabolism. *Nature*. **531**(7596), 651–655. <https://doi.org/10.1038/nature17412>
19. Fornes O., Castro-Mondragon J.A., Khan A., van der Lee R., Zhang X., Richmond P.A., Modi B.P., Correard S., Gheorghe M., Baranasic D., Santana-Garcia W., Tan G., Cheneby J., Ballester B., Parcy F., Sandelin A., Lenhard B., Wasserman W.W., Mathelier A. (2020) JASPAR 2020: update of the open-access database of transcription factor binding profiles. *Nucleic Acids Res.* **48**(D1), D87–D92. <https://doi.org/10.1093/nar/gkz1001>
20. Lesurf R., Cotto K.C., Wang G., Griffith M., Kasai K., Jones S.J., Montgomery S.B., Griffith O.L.; Open Regulatory Annotation Consortium. (2016) ORegAnno 3.0: a community-driven resource for curated regulatory annotation. *Nucleic Acids Res.* **44**(D1), D126–D132. <https://doi.org/10.1093/nar/gkv1203>
21. Kazachenka A., Bertozzi T.M., Sjoberg-Herrera M.K., Walker N., Gardner J., Gunning R., Pahita E., Adams S., Adams D., Ferguson-Smith A.C. (2018) Identification, characterization, and heritability of murine metastable epialleles: implications for non-genetic inheritance. *Cell*. **175**(5), 1259–1271.e13. <https://doi.org/10.1016/j.cell.2018.09.043>
22. Li M.J., Wang L.Y., Xia Z., Sham P.C., Wang J. (2013) GWAS3D: detecting human regulatory variants by integrative analysis of genome-wide associations, chromosome interactions and histone modifications. *Nucleic Acids Res.* **41**(Web Server issue), W150–W158. <https://doi.org/10.1093/nar/gkt456>
23. Huang D., Yi X., Zhang S., Zheng Z., Wang P., Xuan C., Sham P.C., Wang J., Li M.J. (2018) GWAS4D: multidimensional analysis of context-specific regulatory variant for human complex diseases and traits. *Nucleic Acids Res.* **46**(W1), W114–W120. <https://doi.org/10.1093/nar/gky407>
24. Huang D., Zhou Y., Yi X., Fan X., Wang J., Yao H., Sham P.C., Hao J., Chen K., Li M.J. (2022) VannoPortal: multiscale functional annotation of human genetic variants for interrogating molecular mechanism of traits and diseases. *Nucleic Acids Res.* **50**(D1), D1408–D1416. <https://doi.org/10.1093/nar/gkab853>
25. Lee R., Kang M.K., Kim Y.J., Yang B., Shim H., Kim S., Kim K., Yang C.M., Min B.G., Jung W.J., Lee E.C., Joo J.S., Park G., Cho W.K., Kim H.P. (2022) CTCF-mediated chromatin looping provides a topological framework for the formation of phase-separated transcriptional condensates. *Nucleic Acids Res.* **50**(1),

- 207–226.
<https://doi.org/10.1093/nar/gkab1242>
26. Putt W., Palmen J., Nicaud V., Tregouet D.A., Tahri-Daizadeh N., Flavell D.M., Humphries S.E., Talmud P.J.; EARSII group. (2004) Variation in *USF1* shows haplotype effects, gene : gene and gene : environment associations with glucose and lipid parameters in the European Atherosclerosis Research Study II. *Hum. Mol. Genet.* **13**(15), 1587–1597.
<https://doi.org/10.1093/hmg/ddh168>
27. Laurila P.P., Naukkarinen J., Kristiansson K., Ripatti S., Kauttu T., Silander K., Salomaa V., Perola M., Karhunen P.J., Barter P.J., Ehnholm C., Peltonen L. (2010) Genetic association and interaction analysis of *USF1* and *APOA5* on lipid levels and atherosclerosis. *Arterioscler. Thromb. Vasc. Biol.* **30**(2), 346–352.
<https://doi.org/10.1161/ATVBAHA.109.188912>
28. Taghizadeh E., Mirzaei F., Jalilian N., Ghayour Mobarhan M., Ferns G.A., Pasdar A. (2020) A novel mutation in *USF1* gene is associated with familial combined hyperlipidemia. *IUBMB Life.* **72**(4), 616–623.
<https://doi.org/10.1002/iub.2186>
29. Pollard K.S., Hubisz M.J., Rosenbloom K.R., Siepel A. (2010) Detection of nonneutral substitution rates on mammalian phylogenies. *Genome Res.* **20**(1), 110–121.
<https://doi.org/10.1101/gr.097857.109>
30. Caron B., Luo Y., Rausell A. (2019) NCBoost classifies pathogenic non-coding variants in Mendelian diseases through supervised learning on purifying selection signals in humans. *Genome Biol.* **20**(1), 32.
<https://doi.org/10.1186/s13059-019-1634-2>
31. Siepel A. (2005) Evolutionarily conserved elements in vertebrate, insect, worm, and yeast genomes. *Genome Res.* **15**(8), 1034–1035.
<https://doi.org/10.1101/gr.3715005>
32. Hubisz M.J., Pollard K.S., Siepel A. (2011) PHAST and RPHAST: phylogenetic analysis with space/time models. *Brief. Bioinform.* **12**(1), 41–51.
<https://doi.org/10.1093/bib/bbq072>
33. Zerbino D.R., Achuthan P., Akanni W., Amode M.R., Barrell D., Bhai J., Billis K., Cummins C., Gall A., Giron C.G., Gil L., Gordon L., Haggerty L., Haskell E., Hourlier T., Izuogu O.G., Janacek S.H., Juettemann T., To J.K., Laird M.R., Lavidas I., Liu Z., Loveland J.E., Maurel T., McLaren W., Moore B., Mudge J., Murphy D.N., Newman V., Nuhn M., Ogeh D., Ong C.K., Parker A., Patricio M., Riat H.S., Schuilenburg H., Sheppard D., Sparrow H., Taylor K., Thormann A., Vullo A., Walts B., Zadissa A., Frankish A., Hunt S.E., Kostadima M., Langridge N., Martin F.J., Muffato M., Perry E., Ruffier M., Staines D.M., Trevanion S.J., Aken B.L., Cunningham F., Yates A., Flicek P. (2018) Ensembl 2018. *Nucleic Acids Res.* **46**(D1), D754–D761.
<https://doi.org/10.1093/nar/gkx1098>
34. Gulko B., Hubisz M.J., Gronau I., Siepel A. (2015) A method for calculating probabilities of fitness consequences for point mutations across the human genome. *Nat. Genet.* **47**(3), 276–283.
<https://doi.org/10.1038/ng.3196>
35. Freund M.K., Burch K.S., Shi H., Mancuso N., Kichaev G., Garske K.M., Pan D.Z., Miao Z., Mohlke K.L., Laakso M., Pajukanta P., Pasaniuc B., Arbolda V.A. (2018) Phenotype-specific enrichment of Mendelian disorder genes near GWAS regions across 62 complex traits. *Am. J. Hum. Genet.* **103**, 535–552.
<https://doi.org/10.1016/j.ajhg.2018.08.017>
36. Spataro N., Rodriguez J. A., Navarro A., Bosch E. (2017) Properties of human disease genes and the role of genes linked to Mendelian disorders in complex disease aetiology. *Hum. Mol. Genet.* **26**, 489–500.
<https://doi.org/10.1093/hmg/ddw405>
37. Zhang S., He Y., Liu H., Zhai H., Huang D., Yi X., Dong X., Wang Z., Zhao K., Zhou Y., Wang J., Yao H., Xu H., Yang Z., Sham P.C., Chen K., Li M.J. (2019) regBase: whole genome base-wise aggregation and functional prediction for human non-coding regulatory variants. *Nucleic Acids Res.* **47**(21), e134.
<https://doi.org/10.1093/nar/gkz774>
38. Plotz G., Raedle J., Spina A., Welsch C., Stallmach A., Zeuzem S., Schmidt C. (2008) Evaluation of the MLH1 I219V alteration in DNA mismatch repair activity and ulcerative colitis. *Inflamm. Bowel Dis.* **14**(5), 605–611.
<https://doi.org/10.1002/ibd.20358>
39. Vietri M.T., Riegler G., De Paola M., Simeone S., Boggia M., Improta A., Parisi M., Molinari A.M., Cioffo M. (2009) I219V polymorphism in *hMLH1* gene in patients affected with ulcerative colitis. *Genet. Test. Mol. Biomarkers.* **13**(2), 193–197.
<https://doi.org/10.1089/gtmb.2008.0088>
40. Li S., Zhang L., Chen T., Tian B., Deng X., Zhao Z., Yuan P., Dong B., Zhang Y., Mo X. (2011) Functional polymorphism rs189037 in the promoter region of *ATM* gene is associated with angiographically characterized coronary stenosis. *Atherosclerosis.* **219**(2), 694–697.
<https://doi.org/10.1016/j.atherosclerosis.2011.08.040>
41. Li Z., Yu J., Zhang T., Li H., Ni Y. (2013) rs189037, a functional variant in *ATM* gene promoter, is associated with idiopathic nonobstructive azoospermia. *Fertil. Steril.* **100**(6), 1536–1541.e1.
<https://doi.org/10.1016/j.fertnstert.2013.07.1995>
42. Ding X., Yue J.R., Yang M., Hao Q.K., Xiao H.Y., Chen T., Gao L.Y., Dong B.R. (2015) Association between the rs189037 single nucleotide polymorphism in the *ATM* gene promoter and cognitive impairment. *Genet. Mol. Res.* **14**(2), 4584–4592.
<https://doi.org/10.4238/2015.May.4.17>
43. Ding X., He Y., Hao Q., Chen S., Yang M., Leng S.X., Yue J., Dong B. (2018) The association of single nucleotide polymorphism rs189037C>T in *ATM* gene with coronary artery disease in Chinese Han populations: a case control study. *Medicine (Baltimore).* **97**(4), e9747.
<https://doi.org/10.1097/MD.00000000000009747>

Regulatory Potential of SNP Markers in the Genes of DNA Repair Systems

N. P. Babushkina¹, * and A. N. Kucher¹

¹Research Institute of Medical Genetics, Tomsk National Research Medical Center, Russian Academy of Sciences, Tomsk, 634050 Russia

*e-mail: nad.babushkina@medgenetics.ru

In non-coding regions of the genome, the widest range of SNP markers associated with human diseases and petrogenetically significant features were identified. This raised the critical question of identifying the mechanisms that explain these associations. Previously, we identified a number of associations of polymorphic variants of genes encoding DNA repair proteins with multifactorial diseases. To clarify the possible mechanisms underlying established associations, we carried out a detailed annotation of the regulatory potential of the studied markers using a number of on-line resources (GTxPortal, VannoPortal, Ensemble, RegulomeDB, Polympact, UCSC, GnomAD, ENCODE, GeneHancer, EpiMap Epigenomics 2021, HaploReg, GWAS4D, JASPAR, ORegAnno, DisGeNet, OMIM). The article characterizes the regulatory potential of polymorphic variants rs560191 (in the *TP53BP1* gene), rs1805800 and rs709816 (in the *NBN* gene), rs473297 (*MRE11*), rs189037 and rs1801516 (*ATM*), rs1799977 (*MLH1*), rs1805321 (*PMS2*), rs20579 (*LIG4*). Both the general characteristics of the studied markers and information on their influence on the expression of "own" and co-regulated genes, on changes in binding affinity of transcription factors are given. Known data on both adaptogenic and pathogenicity potential of these SNPs and on histone modifications co-localized with them are presented. The potential involvement in regulatory function of not only genes that contain SNPs studied but also nearby genes may explain the association of the markers with diseases and their clinical phenotypes.

Keywords: SNP, associations, gene regulation, splicing, transcription factors, histone code, pathogenicity score, sequence conservation