

مقایسه برنامه‌های سرهمبندی و آنالیز هستی‌شناسی با استفاده از داده‌های حاصل از توالی یابی ترنسکرپتوم زرین‌گیاه (*Dracocephalum kotschyi* Boiss.)

عبدالناصر پورصلواتی^۱، امین ابراهیمی^۲ و سجاد رشیدی منفرد^{*}^۱

^۱ تهران، دانشگاه تربیت مدرس، گروه بیوتکنولوژی کشاورزی

^۲ شاهرود، دانشگاه صنعتی شاهرود، گروه زراعت و اصلاح نباتات

تاریخ دریافت: ۹۶/۱۲/۷ تاریخ پذیرش: ۹۷/۱۰/۲۵

چکیده

با پیشرفت‌های سریع در تکنولوژی توالی‌یابی نسل جدید امروزه این تکنیک به ابزاری قدرتمند و کم‌هزینه برای مطالعات در سطح ترنسکرپتوم تبدیل شده است. سرهمبندی داده‌های حاصل از توالی‌یابی نسل جدید، به صورت *de novo* باعث شکل‌گیری مسیری نوین در مطالعه و شناخت کوئنهای فاقد ژنوم مرجع گردیده است. با گسترش این تکنولوژی و افزایش روز افرون نرم‌افزارهای سرهمبندی، انتخاب مسیر و گزینش نرم‌افزار برتر برای سرهمبندی داده‌های حاصل از توالی‌یابی ترنسکرپتوم به عنوان چالشی برای زیست‌شناسان در این زمینه به شمار می‌آید. در این پژوهش برای اولین بار داده‌های حاصل از توالی‌یابی ترنسکرپتوم زرین‌گیاه با استفاده از نرم‌افزارهای SOAPdenovo-Trans، Oases-velvet و Trinity و Trans-ABySS به دو صورت مختلف با استفاده از متغیر $K=25$ و $K=32$ به منظور دستیابی به مسیر مناسب و نرم‌افزار برتر در این زمینه مورد ارزیابی و آنالیز قرار گرفت. نتایج حاصل از سرهمبندی براساس معیارهای متعدد مقایسه شده که گویای برتری Trinity و Trans-ABYSS می‌باشد، در پایان خروجی حاصل از بهترین سرهمبندی به منظور بررسی فراوانی ایزوفرمهای مختلف و آنالیز هستی‌شناسی (Gene Ontology) مورد ارزیابی قرار گرفت. با توجه به خواص دارویی و مقادیر بالای متابولیتهای ثانویه در این گیاه؛ بیشترین فراوانی مشاهده شده در بخش فرآیندهای زیستی، مربوط به فعالیتهای متابولیتی (Metabolic Process) بود.

واژه‌های کلیدی: Trinity, SOAPdenovo-Trans, Oases-velvet, Trans-ABySS, Gene Ontology

* نویسنده مسئول، تلفن: ۰۲۱۴۸۲۹۲۳۵۷، پست الکترونیکی: rashidims@modares.ac.ir

مقدمه

و ۴۶) امروزه با استفاده از تکنولوژی NGS، امکان توالی‌یابی و شناسایی طیف بسیار گسترده‌ای از ژنها در مدتی کوتاه و در میان ژنوم پیچیده و عظیم گیاهی فراهم‌آمده است (۴۰). از سوی دیگر نرم‌افزارهای متعددی برای سرهمبندی خوانش‌های خام (Raw Read) حاصل از توالی‌یابی به وسیله هم‌دیفی خوانشها بر روی ژنوم مرجع (Reference assembly) معرفی شده که عمل شناسایی ژن را در محیط نرم‌افزاری انجام می‌دهند (۱۱)، اما ژنوم‌مرجع برای بسیاری از گونه‌ها از جمله گونه مورد

در سالهای اخیر آنالیز ترنسکرپتوم به عنوان یکی از مراحل بنیادی در مطالعات زیستی مطرح شده که به‌این منظور روش‌های متعددی از جمله؛ نورترن بلاط (Northern blot)، واکنش زنجیره ای پلیمراز رونوشت برداری معکوس (RT-PCR)، ریزآرایه‌ها (Microarray) و توالی‌یابی به روش‌های سنتی را می‌توان نام برد (۳۰) و با توجه به پیشرفت‌های سریع در توالی‌یابی نسل جدید (Next-generation sequencing: NGS) ابزاری قدرتمند در آنالیز ترنسکرپتوم تبدیل شده است (۳۰).

گردید (۴۶). در تحقیقی دیگر برای سرهم بندی داده‌های حاصل از توالی‌بایی با سیستم ۴۵۴ برای اولین بار از ابزارهای مبتنی بر الگوریتم De Bruijn graph استفاده شد (۳۳). با این همه در تحقیقات انجام شده برای مقایسه نرمافزارها به طور معمول از داده‌های موجودات مدل استفاده شده و این در حالی است که این پژوهش خواشنهای زرین‌گیاه را به صورت *de novo* و بر اساس مقادیر مختلف K برای سرهمندی درنظر گرفته است. بایستی به این نکته نیز توجه نمود که الگوریتمهای این برنامه‌ها در حال به روزرسانی است و مقایسه آخرین ورژن برنامه‌ها برای به دست آوردن نتیجه مطلوب ضروری می‌نماید.

زرین‌گیاه با نام علمی *Dracocephalum kotschy* یکی از گونه‌های ایندیمیک ایران است که در شمال، غرب و مرکز ایران یافت شده (۳۲) و با نام بادرنجویه‌دنایی نیز شناخته می‌شود (۳۱). با توجه به تعداد کم و خطر انقراض بالقوه، ضرورت حفاظت، اصلاح و اهلی کردن این گیاه بیش از هر زمانی احساس می‌شود (۱۲ و ۲۰). زرین‌گیاه در طبستی و داروسازی نیز مورد توجه بوده و تحقیقات متعددی روی آن صورت گرفته است (۴، ۲۱، ۲۲، ۳۶ و ۴۴). با این حال، میزان پژوهش‌های بیوانفورماتیکی صورت گرفته در زمینه گیاهان ارزشمند دارویی بسیار اندک بوده و به گواه بانک اطلاعاتی NCBI به جز یک توالی rRNA و سه توالی کلروپلاستی، هیچ‌گونه فعالیت و پژوهشی در راستای آنالیزهای مولکولی بر روی زرین‌گیاه صورت نگرفته است (۴۸).

اکنون با استفاده از روش‌های نوین با کارآیی بالا و بهره‌گیری از نرمافزارهای بیوانفورماتیکی برای تبدیل داده‌های خام به اطلاعات مفید و آنالیزهای (In silico می‌توان اقدام به شناسایی هرچه بهتر این گیاه نمود و برای دست‌یابی مؤثر و کارآمد به این هدف، اولین گام انتخاب ابزار و نرمافزار مناسب با کارآیی و دقیقت بالاست. هدف از

مطالعه در این پژوهش (زرین‌گیاه) در دسترس نیست. با این وجود و با بهره‌گیری از نرمافزارهای به روز و معرفی تکنیکهای NGS امکان مطالعه در سطوح «امیک» (Omics) برای گونه‌های فاقد نقشه ژنومی نیز فراهم آمده (۷)، که در این حالت سرهمندی *de novo* این امکان را ایجاد کرده تا توالی کاملی از ترانسکریپتوم موجود بازسازی و ژنهای بیان شده در یک بافت خاص شناسایی، مقدار سنجی و دسته‌بندی گردد (۴۶).

اولین تلاشها در مطالعات نوین ترانسکریپتوم با استفاده از داده‌های RNA-Seq در سال ۲۰۰۹ به وسیله ونگ و همکاران تحت عنوان ابزاری انقلابی در مطالعه ترانسکریپتوم مطرح شد (۴۰). نرمافزارهای مربوط در این روش، برای سرهمندی از دو الگوریتم مختلف De Bruijn graph (۴۵) و Overlap layout-consensus (۱۳) پیروی می‌کنند. در نرمافزارهای نسل جدید از الگوریتم De Bruijn graph استفاده شده که در این روش سرهمندی از طریق شکستن خوانش خام اولیه، به توالیهای کوچک‌تر که K-mer نامیده می‌شوند انجام شده و یافتن همپوشانی میان K-mer ها صورت می‌گیرد (۱۴). نرمافزارهای مورد نظر برای این پژوهش شامل Trinity (v2.4.0)، Oases-Velvet (۴۲)، SOAPdenovo-Trans (v1.03)، Trans-ABYSS (v1.5.0) و (۳۷) (v0.2.08) بوده که همگی از الگوریتم De Bruijn graph پیروی کرده و با توجه به گسترده‌گی این دست نرمافزارها و پارامترهای مربوط؛ انتخاب نرمافزار برتر و روش بهینه برای سرهمندی داده‌ها امری ضروری است. در سال ۲۰۱۲ مقایسه‌ای میان سه ابزار مختلف سرهمندی یعنی Oases، Trinity و SOAPdenovo حاصل از سیب زمینی شیرین به منظور یافتن پوشش ژنومی قوی‌تر انجام گرفت (۳۸). همچنین بر روی خواشنهای مگس سرکه موجود در دیتابیس، مقایسه میان نرمافزارهای سرهمندی صورت گرفته و نتایج حاصل از سرهمندی با ژنهای شناخته شده این موجود مقایسه

حذف گردید. در ادامه عمل Normalization بر روی داده‌های خام اعمال گردید که این مرحله با استفاده از ابزار Trinity In Silico Normalization که در بسته نرم‌افزاریNormalization قرار دارد صورت گرفت. فرآیند Normalization براساس فرمول $P=\min(1, T/C)$ صورت گرفته (۱۷) که در این پژوهش پارامتر T (Max Target Coverage) در تنظیمات این حالت برای خوانش‌های پرتکرار حداقل ۳۰ تکرار از هر خوانش حفظ شده و مابقی حذف خواهد شد (۱۸). همچنین این مقدار توسط Haas و همکاران به عنوان مقدار بهینه در هنگام سرهمندی خوانشها توصیه شده است (۱۷).

سرهمندی خوانش‌های حاصل از توالی‌بایی: نتایج حاصل از مراحل قبل به منظور سرهمندی و تشکیل توالی‌های ترنسکرپتوم با استفاده از نرم‌افزارهای (v2.4.0)، Trinity، Oases-Velvet (v0.2.08)، SOAPdenovo-Trans (v1.03) و (v1.5.5)، Trans-ABYSS (v1.5.5) مورد آنالیز و ارزیابی قرار گرفت. به منظور بررسی تأثیر پارامترهای دخیل در سرهمندی، این فرآیند با دو مقدار مختلف ۲۵ و ۳۲ برای Oases-Velvet K در تمامی نرم‌افزارها (به جز نرم‌افزار Velvet که فقط متغیرهای فرد را پذیرفته و مقدار ۳۳ برای آن در نظر گرفته شد) استفاده گردید. براساس مطالعات پیشین؛ بالاترین اندازه برای N50 هنگامی ایجاد می‌شود که بازه عددی ۲۵ تا ۳۵ برای K -mer در نظر گرفته شده و مقادیر ۲۵ و ۳۲ در اکثر مطالعات دیگر نیز مورد استفاده قرار گرفته است (۴۷، ۴۱، ۵ و ۹). همچنین مقدار ۲۵ به عنوان پیش‌فرض، در برخی از نرم‌افزارهای مورد بررسی، استفاده شده و از سوی دیگر در نرم‌افزار Trinity نیز بیشترین عدد مورد پذیرش برای متغیر K -mer، مقدار ۳۲ بود (۱۵). نرم‌افزارهای مورد استفاده در این پژوهش تا زمان نوشتمن این مقاله، آخرین نسخه منتشر شده از سوی توسعه‌دهندگان بوده و برای بی‌اثر کردن شرایط محیطی، تمامی آنالیزها در سیستم عامل لینوکس و در شرایط مشابه

این پژوهش بررسی مهمترین نرم‌افزارهای موجود در این زمینه و دستیابی به مسیری قابل اعتماد و کارآمد برای سرهمندی خوانشها به صورت *de novo* جهت آنالیزهای پایین‌دست می‌باشد. امید است نتایج حاصل از این پژوهش بتواند در موارد مشابه راه‌گشای محققین در تحقیقات آتی قرار گیرد.

مواد و روشها

جمع‌آوری نمونه‌های گیاهی و استخراج mRNA در این پژوهش، از زرین گیاه موجود در ارتفاعات رشته‌کوه‌های زاگرس در استان لرستان، شهرستان الشتر (با مشخصات، ارتفاع از سطح دریا: ۳۵۸۵ متر، عرض جغرافیایی: ۳۳,۹۵۵۹۹۶ و طول جغرافیایی: ۴۸,۳۲۰۱۱) نمونه‌های برگ جمع‌آوری و در ازت مایع به آزمایشگاه منتقل گردید. مراحل استخراج RNA با کیفیت بالا از ۱۰۰ میلی‌گرم بافت منجمد شده گیاهی با استفاده از کیت استخراج RNeasy Plant Mini Kit (QIAGEN., Cat No.: 74904) انجام گرفت. کیفیت و کمیت RNA استخراج شده توسط ژل آگارز ۱ درصد و نانودرایپ بررسی شده و مجموعه RNA حاصل از استخراج جهت توالی‌بایی دوطرفه (paired end) با ۲۰ میلیون خوانش به طول ۱۵۰ جفت‌باز به وسیله دستگاه ۲۰۰۰ Illumina HiSeqTM برای شرکت توپاز ارسال شد.

بررسی کیفیت نتایج توالی‌بایی، Trimming و Normalization: نتایج حاصل از توالی‌بایی شامل ۴۷ میلیون خوانش به طول ۱۵۰ جفت‌باز، در قالب فایل FASTQ (FASTQ) از طرف شرکت ارسال گردید. این خوانشها Trim شده بودند و توالی آداتور از ابتدای آنها برش خورده بود. کیفیت داده‌های خام با استفاده از نرم‌افزار FastQC (Version 0.11.5; Simon Andrews) سنجش قرار گرفت و برای رسیدن به صحت و دقت بالاتر در سرهمندی، توالی‌بایی با کیفیت کمتر با استفاده از نرم‌افزارهای Trimmomatic (v0.36) (۸) و AfterQC (۶) و

با استفاده از هم‌دیفی و شمارش تعداد خوانشها برای هر رونوشت با در نظر گرفتن طول رونوشت محاسبه گردید. سپس با استفاده از اسکریپت filter_low_expr_transcripts از مجموعه Trinity، به ازای هر ژن تنها یک ایزوform که دارای بیشترین فراوانی بود برای ادامه مسیر انتخاب شد.

مستندسازی نتایج و آنالیز GO (Gene Ontology): تمامی رونوشت‌های مورد مطالعه، در ابتدا با استفاده از BLASTX (۳) در برابر پایگاه داده گیاه آرابیدوپسیس تالیانا (*Arabidopsis thaliana*) به شماره اختصاصی (taxid:3702) مورد ارزیابی قرار گرفت. هدف از این کار؛ مستندسازی رونوشت‌ها با حساسیت بالا ($1e-5$) در برابر اطلاعات فراوان پروتئینی در گیاه آرابیدوپسیس تالیانا به عنوان گیاه مدل می‌باشد که در غیر این صورت امکان بررسی هستی‌شناسی در ادامه فراهم نخواهد بود، زیرا برای انجام تجزیه و تحلیل هستی‌شناسی با استفاده از ابزارهایی مانند PANTHER یا AgriGO تنها بررسی ژنهای شناخته شده و دارای شناسه GO در گیاهان محدودی از جمله آرابیدوپسیس تالیانا، برنج، کاهو، گندم و غیره... امکان‌پذیر بوده که در این میان گیاه آرابیدوپسیس تالیانا بیشترین شناسه GO منحصر به فرد را در میان سایر گیاهان به خود اختصاص داده است. این فرآیند پیش از این، در پژوهش‌های مشابه برای مستندسازی و هستی‌شناسی رونوشت‌ها صورت پذیرفته است (۱۶ و ۲۹). برای افزایش هرچه بیشتر دقت و اطمینان از نتایج حاصل از این ارزیابی مقدار $10^{-5} \leq E\text{-value}$ در نظر گرفته شد. سپس با طراحی اسکریپت مجزایی نتایج حاصل از BLASTX به منظور دست‌یابی و جداسازی معتبرترین پاسخ برای هر رونوشت مورد بررسی قرار گرفت؛ که در طراحی این اسکریپت ابتدا تمامی نتایج حاصل از BLASTX برای هر رونوشت به طور مجزا بر اساس مقدار E-value پایین‌تر و امتیاز بالاتر مرتب گردیده و سپس بهترین نتیجه به ازای هر رونوشت در فایل خروجی نهایی ذخیره و ثبت گردید. در آخر با

از نظر مشخصات سیستمی (Ram=40GB, CPU=2.4GHz×16, OS=Ubuntu Linux 16.04 LTS) صورت گرفت. در ادامه همه فایلهای خروجی سرهمندی شده از تمامی نرم‌افزارهای مورد مطالعه، براساس حداقل طول توالی، با استفاده از ابزار فیلتر طول (fasta_filter_by_min_length) از مجموعه Trinity به مقدار ۲۰۰ جفت‌باز فیلتر گردید. مقدار ۲۰۰ جفت باز، با توجه به طول خوانش‌های اولیه ۱۵۰ و مقادیر درنظر گرفته شده برای متغیر K (۲۵ و ۳۲)، می‌تواند مبنای مناسبی برای فیلتر کردن نتایج سرهمندی باشد. همچنین با توجه به این نکته که در این حالت کوچکترین پروتئین حاصل از سرهمندی، طولی در حدود ۶۶ آمینواسید خواهد داشت. بهاین ترتیب همه فایلهای خروجی از نظر حداقل طول بازسازی شده، یکسان گردید و از توالی‌های کوتاه‌تر و بی‌معنی که به طور معمول حاصل از ضعف الگوریتمها و ابزارهای سرهمندی بوده، چشم‌پوشی شد. در مرحله بعد فایلهای حاصل از سرهمندی بر اساس پارامترهای تعداد توالی، N50، طول بیشینه و کمینه، میانگین طول توالی‌های ایجاد شده، زمان مورد نیاز برای اجرا (RunTime) بررسی گردید.

هم‌دیفی خوانش‌های اولیه روی خروجی‌های سرهمندی: در ادامه خوانش‌های خام اولیه (قبل از فرآیند Bowtie2 v2.3.2) با استفاده از نرم‌افزار (Normalization) (۲۳) بر روی تمامی فایلهای خروجی شامل؛ سرهمندی با مقادیر $K=25$ و $K=32$ همچنین قبل از اعمال فیلتر ۲۰۰ و بعد از آن، هم‌دیف گردید. بهاین ترتیب نرخ هم‌دیفی (Coverage values) و میزان پوشش (Alignment rate) ایجاد شده میان نرم‌افزارهای مختلف مورد بررسی و مقایسه قرار گرفت.

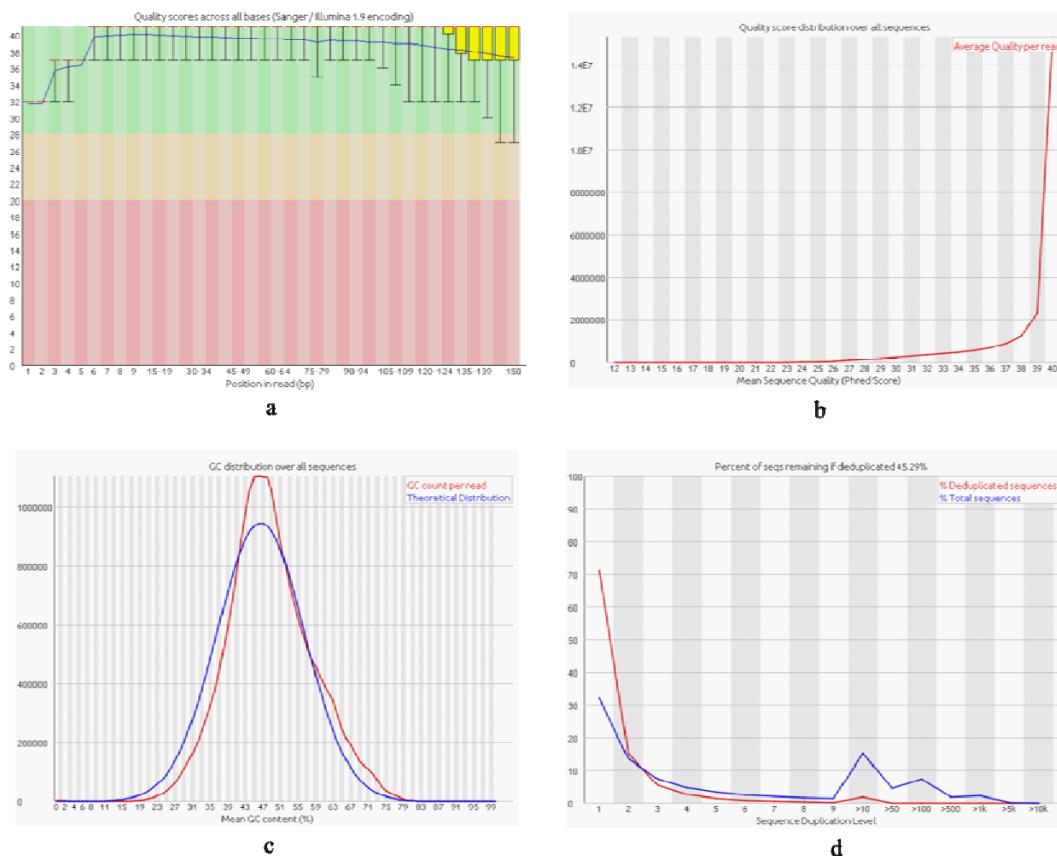
برآورد میزان فراوانی رونوشت‌های حاصل از سرهمندی: برای بررسی میزان فراوانی رونوشت‌های حاصل از سرهمندی، از ابزار RSEM (۲۴) بهره برده که این فرآیند

توالی‌بایی توسط FastQC بررسی گردید (شکل ۱) و با توجه به کیفیت قابل قبول خوانشها، سه نوکلتوئید از انتهای ۳ برخی خوانشها با استفاده از ابزار Trimmomatic و AfterQC حذف شد.

استفاده از شماره اختصاصی مرتبط به هریک از نتایج، فرآیند هستی‌شناسی ژنها (Gene Ontology) در ابزار آنلاین PANTHER (۲۷) انجام شد.

نتایج

پس از دریافت خوانش‌های حاصل از توالی‌بایی دوطرفه با استفاده از دستگاه Illumina HiSeqTM 2000 کیفیت نتایج



شکل ۱- کیفیت خوانشها برای هر توالی (a)، کیفیت خوانشها برای هر نوکلتوئید (امیاز Phred) (b)، میزان توالیهای تکراری در خوانشها (c)، مقدار GC در توالی خوانشها (d)

در ادامه باتوجه به نتایج FastQC و وجود خوانشها تکراری فراوان در داده‌های خام؛ به منظور سهولت و سرعت بالاتر در فرآیند سرهمندی و از سوی دیگر به علت محدودیت در منابع سیستمی برای آنالیز داده‌ها، لازم است فرآیند Normalization بر روی خوانشها اعمال شود. به این ترتیب برای فایل خام اولیه که دارای ۲۳,۵۹۹,۴۹۵ خوانش با طول ۳,۵۳۹,۹۲۴,۲۵۰ نوکلتوئید با درصد GC

۴۸ و حجم ۸/۵ گیگابایت می‌باشد؛ بدون از دادن خوانشها با تکرار کمتر از ۳۰، خوانش‌های تکراری از فایل اولیه حذف شده و نتیجه حاصل از آن، ایجاد فایل نرم‌افزاری شده نهایی با ۶,۵۲۹,۸۵۳ خوانش به طول ۹۷۹,۴۷۷,۹۵۰ نوکلتوئید و درصد GC ۴۵ به حجم ۲/۴ گیگابایت بود (تمامی فایلهای ذکر شده در قالب FASTQ قرار دارند).

شده به طور پیش‌فرض ۲۰۰ جفت‌باز بوده و به این ترتیب خروجیهای سایر نرم‌افزارها با استفاده از ابزار فیلتر طول، به میزان ۲۰۰ نوکلئوتید فیلتر گردید.

در ادامه برای رسیدن به میزان صحت و پوشش خوانشها بر روی فایلهای خروجی، خوانش‌های اولیه (قبل از نرمالایز شدن) بر روی تمامی فایلهای سرهمندی شده حاصل از نرم‌افزارهای مختلف توسط Bowtie2 هم‌دیف شده و نرخ هم‌دیفی برای هر نرم‌افزار در هر فایل خروجی بررسی گردید (۳۹). خروجیهای مختلف تمام نرم‌افزارها؛ قبل و بعد از فیلتر ۲۰۰ که در مجموع شامل ۳۰ فایل سرهمندی مختلف می‌باشد در جدول ۱ باهم مقایسه شده است. به این ترتیب با در نظر گرفتن $K=25$ ، متغیر N50 که بیانگر حداقل طول ۵۰ درصد از توالیهای سرهمندی شده می‌باشد (۲۸) برای خروجی transcripts از نرم‌افزار transabyss.ref از Oases-Velvet (۱۹۷۶ bp) و همچنین خروجی Trinity (۱۱۹۳ bp) Trans-ABYSS (۱۵۸۵ bp) در مقدار قابل قبولی قرار دارند و باتوجه به تعداد توالیهای ایجاد شده، خروجی Trinity، Fайل Oases-Velvet از نرم‌افزار transcripts در وضعیت بهتری گرفته شد، Fایل از نرم‌افزار Trans-ABYSS (۲۱۴۷ bp)، خروجی Transabyss.ref از نرم‌افزار (۱۶۴۷ bp) و خروجی ABYSS (۱۳۱۲ bp) Trinity بیشترین مقدار N50 را به خود اختصاص داده (جدول ۱) و در مطالعات قبلی که روی Trinity، SOAPdenovo و Trans-ABYSS صورت گرفت نیز نتایج مشابهی به دست آمد؛ همچنین در اثر افزایش مقدار K -mer N50 به طور محسوس افزایش یافته که در این پژوهش نیز نتایج به دست آمده بیانگر این مورد است (۹ و ۲۵).

بر اساس تعداد توالی پیش‌بینی شده باتوجه به میزان N50 هریک از خروجیها، در هر دو حالت $K=32$ و $K=25$ ، Fایل transabyss-final تعداد بیشتری توالی را بازسازی

سپس فرآیند سرهمندی با استفاده از خوانش‌های نرمالایز شده از مرحله قبل و نرم‌افزارهای ذکر شده صورت گرفت. تمامی نرم‌افزارهای مورد استفاده به جز Trinity همگی براساس نسخه ژنومی آنها ایجاد شده‌اند، بهاین صورت که (Framework) SOAPdenovo-Trans در چهارچوب Trans-ABYSS، SOAPdenovo و Oases با استفاده از نسخه ژنومی آن یعنی Velvet نوشته شده، در حالی که Trinity به طور اختصاصی برای سرهمندی داده‌های حاصل از توالی‌بایی تنسکریپتوم توسعه داده شده است. از سوی دیگر درحالی که تمامی این نرم‌افزارها از فرآیند ایجاد K-mer و الگوریتم De Bruijn graph برای سرهمندی خوانشها استفاده می‌کنند، ولی باتوجه به گزینه‌ها و متغیرهای خود، فرآیند متفاوتی برای ایجاد فایل رونوشتنهایی و سرهمندی K-mer ها درنظر می‌گیرند. در تنها Trinity یک فایل سرهمندی به عنوان خروجی ایجاد شده و شامل ایزوفرمها و یونی ژنها می‌باشد؛ این درحالی است که سایر نرم‌افزارها علاوه بر ایجاد فایل کانتیگ (Contig) اولیه؛ قادر به ایجاد سطح بالاتری از سرهمندی به نام اسکفولد (Scaffold) براساس الگوریتم Overlap layout-consensus تشکیل شده باشد ولی در مراحل بعد و آنالیزهای پایین دست می‌تواند مورد استفاده قرار گیرد.

در SOAPdenovo-Trans Fایلهای خروجی شامل Contig و ScafSeq و نرم‌افزار Oases-Velvet نیز دارای دو فایل Transcripts با نامهای Contigs و Trans-Transabyss.jn، AbySS به حداقل طول توالیهای مختلف در فایلهای خروجی هریک از نرم‌افزارها و به منظور بی‌اثر کردن تأثیر توالیهای کوتاه در این پژوهش، فایلهای حاصل از سرهمندی برای ادامه کار تحت تأثیر فیلتر طول به میزان ۲۰۰ جفت‌باز قرار گرفت. در نرم‌افزار Trinity، حداقل طول توالی بازسازی

با در نظر گرفتن $K=25$ بیشترین همردیفی مربوط به Trinity (۷۰/۸۷ درصد) و خروجی transabyss.final (۶۷/۷۱ درصد) همچنین در حالت $K=32$ نیز خروجی (۷۲/۹۸) Trinity (۷۵/۴۹ درصد) و transabyss.final (درصد) بیشترین مقادیر را به خود اختصاص داده (جدول ۱) که در مطالعه سال ۲۰۱۲ روی دروزوفیلا نتایج مشابهی برای پوشش ژنومی خوانشها در برابر ژنوم مرجع موجود در پایگاهداده حاصل آمد (Trinity با $78/6$ درصد و Trans-ABYSS با $64/3$ درصد). همچنین در مطالعه اخیر بر روی نرم‌افزارهای مطرح در این زمینه و سرهمندی خوانش‌های آراییدوپسیس و همردیفی آنها روی ژنوم، نتیجه مشابهی به دست آمد (Trans-ABYSS درصد و Trinity $90/21$ درصد) (۴۱).

همچنین با افزایش مقدار K -mer، تعداد توالیهای تشکیل شده در نرم‌افزار Trinity از 165125 به 165697 و در نرم‌افزار SOAPdenovo-Trans (فایل scafseq) از 68979 به 76223 عدد افزایش یافته و در دو نرم‌افزار دیگر یعنی Oases-Velvet (فایل transcripts) از 124813 به 100048 و در نرم‌افزار Trans-ABYSS (فایل Oases-Velvet) از 390072 به 286004 عدد کاهش یافته که این امر می‌تواند با الگوریتمهای متفاوت این نرم‌افزارها در سرهمندی در ارتباط باشد. از سوی دیگر طول توالیهای بازسازی شده با افزایش مقدار K -mer به طور محسوس افزایش داشته و تنها در مورد SOAPdenovo-Trans با افزایش مقدار K -mer، میانگین طول توالیها از 421 bp به 405 کاهش یافته و باتوجه به کوتاه شدن توالیهای حاصل از سرهمندی، این امر می‌تواند علت کاهش نرخ همردیفی در وضعیت $K=32$ در خروجی scafseq را توجیه کند. ایجاد تنسکریپت بلندتر و بدون فاصله، نقش مهمی در تشکیل نواحی همپوشان برای آنالیزهای پایین‌دست به منظور شناسایی و پیش‌بینی ORF‌ها (Open Reading Frame) و ژنهای این گیاه دارد (جدول ۱).

نموده ($K=25$ شامل 390072 توالی و $K=32$ شامل 286004 توالی) که در مطالعه Wang و Gribskov نیز این مورد بالاترین تعداد (۱۰۷۰۸۷) را ایجاد نمود (۴۱). پارامتر طول توالیهای بازسازی شده در این پژوهش در حالت $K=25$ نشان‌دهنده برتری Oases-Velvet در فایل transcripts با میانگین طول 1051 bp و در حالت $K=32$ نیز با میانگین طول 1363 bp دارای برتری بوده ولی باتوجه به فواصل خالی (gaps) (۴۳) در توالیهای تشکیل شده توسط Oases-Velvet، این امر می‌تواند امتیازی منفی به شمار آید. در این صورت فایل خروجی Trinity با میانگین طول 1036 bp در $K=25$ و طول 1066 bp در $K=32$ از این نظر موفقیت بیشتری به همراه داشته (جدول ۱) و این مورد در پژوهش‌های پیشین نیز مورد توجه قرار گرفته است (Zhao و Gribskov و همکاران میانگین طول 604 bp و Wang و Oases-velvet نیز برتری را برای میانگین طول بهتر به میزان 1593 bp برای $K=25$ و 1710 bp برای $K=31$ گزارش کردند) (۴۱ و ۴۷). براساس میزان منابع سیستمی، از جمله مقدار رم و زمان مورد نیاز برای اجرا، کمترین مقدار رم و سریع‌ترین زمان SOAPdenovo-Trans (۳۵ دقیقه) برای سرهمندی را به خود اختصاص داده و در مقابل، Trinity علاوه بر مقدار بالاتر رم (یک گیگابایت به ازای هر یک میلیون خوانش (۱۹)، زمان بالاتری (۱۵ ساعت) نیز برای سرهمندی خوانشها صرف می‌کند. البته باید به این نکته توجه نمود که کارآبی آنالیز در هر نرم‌افزار برای سرهمندی خوانشها، ارتباط مستقیمی با دقت و صحت سرهمندی ندارد (۴۷).

همردیف کردن خوانش‌های خام اولیه بر روی خروجی هر نرم‌افزار موجب شکل‌گیری مبنای مناسبی برای مقایسه میان نتایج سرهمندی گردیده که براساس نتایج جدول ۱ با افزایش مقدار K نرخ همردیفی به طور محسوس افزایش یافته و همه‌ی نرم‌افزارها به غیر از SOAPdenovo-Trans افزایش قابل توجهی را در مقدار همردیفی و تعداد خوانش‌های همردیف شده نشان می‌دهند، به این صورت که

مرتبه از جمله N50 حکایت داشته و از طرفی در مقایسه میان دو ابزار دیگر یعنی Oases و ABYSS، به برتری نرمافزار Oases اشاره شده که علت این امر می‌تواند با به روزرسانی‌های متعدد از زمان انتشار مقاله مذکور در ارتباط باشد (۱۰).

در مطالعه‌ای که با استفاده از خوانش‌های شبیه‌سازی شده در کنار خوانش‌های واقعی روی کروموزوم شماره ۲۲ انسان جهت بررسی کارآیی چند نرمافزار سرهمبندی از جمله ABYSS و Oases، Trinity صورت گرفت، نتایج از برتری Trinity در زمینه نرخ پوشش ژنومی و پارامترهای آماری Trinity

جدول ۱- مقایسه نرمافزارهای خوانش‌های حاصل از توالی‌یابی ترانسکرپتوم زرین‌گیاه

	Oases-Velvet		SOAPdenovo-Trans		Trans-ABYSS			Trinity
File names	contigs	Transcripts	contig	scfSeq	Transabyss.jn	Transabyss.ref	Transabyss.final	Trinity
<i>K=۲۵</i>								
N50 bp	۲۶۴ (۹۸)	۲۰۲۸ (۱۹۷۶)	۶۰۶ (۳۵۵)	۱۲۷۳ (۹۹۹)	۶۵۴ (۶۲۲)	۱۳۰۲ (۱۱۹۳)	۹۵۵ (۶۷۶)	۱۵۸۵
Sequence number	۹۹۱۰۲ (۱۳۵۴۶۲۲)	۹۴۹۱۰ (۱۲۴۸۱۳)	۸۹۳۱۸ (۳۰۴۷۷۲)	۶۸۹۷۹ (۱۴۴۰۷۵)	۵۵۳۸۲ (۶۰۰۶۳)	۵۷۰۳۸ (۹۰۳۱۹)	۱۱۲۲۴۲ (۳۹۰۰۷۲)	۱۶۵۱۲۵
Average Length bp	۲۸۲/۹ (۹۱/۹)	۱۳۳۶/۸ (۱۰۵۱)	۵۰۵/۸ (۲۱۹/۲)	۷۷۸ (۴۴۱/۲)	۵۶۷۱ (۵۳۶)	۸۳۳/۷ (۵۳۶/۱)	۶۸۴/۸ (۲۴۸)	۱۰۳۶/۸۸
Max length bp	۲۴۰۰	۱۵۴۲۹	۸۵۵۲	۱۵۰۳۵	۵۲۷۶	۱۲۷۳۰	۱۴۷۳۰	۱۳۲۵۰
Min length	۲۰۰ (۴۹)	۲۰۰ (۱۰۰)	۲۰۰ (۲۶)	۲۰۰ (۱۰۰)	۲۰۰ (۴۸)	۲۰۰ (۲۶)	۲۰۰ (۲۵)	۲۰۱
Alignment Rate %	۰/۷۲ (۰/۷۹)	۵۸/۴۱ (۵۸/۴۳)	۳۹/۵۵ (۳۹/۵۹)	۴۴/۴۵ (۴۴/۴۸)	۱۵/۳۶ (۱۵/۳۸)	۶۷/۵۶ (۶۷/۵۸)	۷۰/۴۸ (۷۰/۹۱)	۹۷/۷۱
Mapped Reads	۱۷۰۸۱۵ (۱۸۵۴۵۹)	۱۳۷۸۴۶۱۴ (۱۳۷۹۰۰۶۸)	۹۳۳۲۸۰۵ (۹۳۴۴۱۸۴)	۱۰۴۹۰۸۸۹ (۱۰۴۹۶۱۴۶)	۳۶۲۴۵۹۹ (۳۶۲۸۵۰۲)	۱۵۹۴۴۱۴۸ (۱۵۹۴۹۴۰۳)	۱۶۷۲۵۵۷۰ (۱۶۷۳۳۴۵۰)	۱۵۹۷۹۱۸
RunTime	۰۰:۰۵' (۰۰:۱۳')	۰۰:۵۸' (۲:۲۰')	۰۰:۲۲' (۰۰:۲۹')	۰۰:۵۹' (۰۰:۲۹')	۰۰:۳۹' (۰۰:۴۱')	۰۰:۳۲' (۰۰:۳۳')	۰۰:۳۹' (۰۰:۴۵')	۱:۵۰' (۰۰:۴۵')
<i>K=۳۲</i>								
N50 bp	۲۶۴ (۱۲۳)	۲۱۷۰ (۲۱۴۷)	۵۸۱ (۳۳۲)	۱۲۸۸ (۹۵۵)	۷۹۱ (۷۸۴)	۱۳۶۵ (۱۳۱۲)	۱۰۵۰ (۸۳۰)	۱۶۴۷
Sequence number	۱۱۴۵۰۳ (۱۰۱۰۰۴۶)	۸۹۶۲۳ (۱۰۰۰۴۸)	۹۵۸۲۶ (۳۰۵۱۳۶)	۷۶۲۲۳ (۱۸۲۹۵۶)	۵۵۰۹۷ (۵۷۹۴۹)	۵۹۳۲۲ (۷۲۹۷۱)	۱۱۵۲۷۴ (۲۸۶۰۰۴)	۱۶۰۵۹۷
Average Length bp	۲۶۸/۶ (۱۱۷)	۱۵۰۱/۸ (۱۳۶۳)	۴۹۰/۶ (۲۳۲/۲)	۷۹۱/۱ (۴۰/۵)	۶۶۲/۶ (۶۴۲/۷)	۸۸۱/۷ (۷۳۹/۸)	۷۴۱/۲ (۳۵۳/۸)	۱۰۶۶/۴
Max length bp	۲۵۶۲	۱۵۸۵۷	۶۸۵۸	۱۵۰۷۵	۴۸۷۷	۱۶۱۵۰	۱۶۱۵۰	۱۲۳۳۱
Min length	۲۰۰ (۶۵)	۱۲۰ (۲۰۰)	۲۰۰ (۳۴)	۲۰۰ (۱۰۰)	۲۰۰ (۷۳)	۲۰۰ (۳۳)	۲۰۰ (۳۲)	۲۰۱
Alignment Rate %	۱/۰۵ (۱/۱۲)	۶۵/۹۲ (۶۵/۹۴)	۴۰/۱۷ (۴۰/۲۲)	۴۲/۰۳ (۴۲/۵۶)	۲۱/۰۹ (۲۱/۶۰)	۷۱/۸۲ (۷۱/۸۳)	۷۵/۰۹ (۷۵/۵۲)	۷۲/۹۸
Mapped Reads	۲۴۸۷۶۸ (۲۶۹۱۹۳)	۱۰۰۵۷۲۲۴ (۱۰۵۶۱۶۴۸)	۹۴۷۹۳۱۴ (۹۴۹۱۳۶۰)	۱۰۲۷۳۸۳۷ (۱۰۲۸۰۲۴۱)	۵۰۹۴۹۹۶ (۵۰۹۷۸۶۶)	۱۶۹۴۹۰۴۴ (۱۶۹۵۱۰۹۳)	۱۷۸۱۴۸۱۷ (۱۷۸۲۲۵۱۱)	۱۷۲۲۳۸۷
RunTime	۰۰:۲۵' (۰۰:۳۶')	۱:۲۸' (۱:۲۰')	۰۰:۲۹' (۰۰:۴۸')	۰۰:۳۲' (۰۰:۵۶')	۰۰:۱۱' (۰۰:۱۶')	۰۰:۵۰' (۰۰:۵۶')	۰۰:۴۸' (۰۰:۵۰')	۲:۰۸' (۰۰:۵۰')

* مقادیر داخل پرانتز بدون فیلتر ۲۰۰ برای حداقل طول توالی محاسبه شده‌اند.

جدول ۲- اطلاعات آماری فایل خروجی سرهمبندی با ابزار Trinity

۶۷۸۵۹	تمام ژنهای Trinity
۱۶۵۵۹۷	تمام رونوشتهاي Trinity
۴۲/۶۴	درصد GC
	اطلاعات آماری بر اساس تمام رونوشتها
۳۳۲۵ bp	Contig N10
۲۶۲۱ bp	Contig N20
۲۱۸۸ bp	Contig N30
۱۸۶۷ bp	Contig N40
۱۶۴۷ bp	Contig N50
۷۴۲ bp	طول میانه
۱۰۳۶/۸۸ bp	طول متوسط
۱۷۱۲۱۵۵۳۱	تعداد بازهای سرهمبندی شده
	اطلاعات آماری بر اساس بلندترین ایزوفرم در هر ژن
۳۲۷۵ bp	Contig N10
۲۵۲۱ bp	Contig N20
۲۰۶۵ bp	Contig N30
۱۶۹۳ bp	Contig N40
۱۳۵۳ bp	Contig N50
۴۴۶ bp	طول میانه
۷۹۵/۶۲ bp	طول متوسط
۵۳۹۸۹۹۷۲	تعداد بازهای سرهمبندی شده

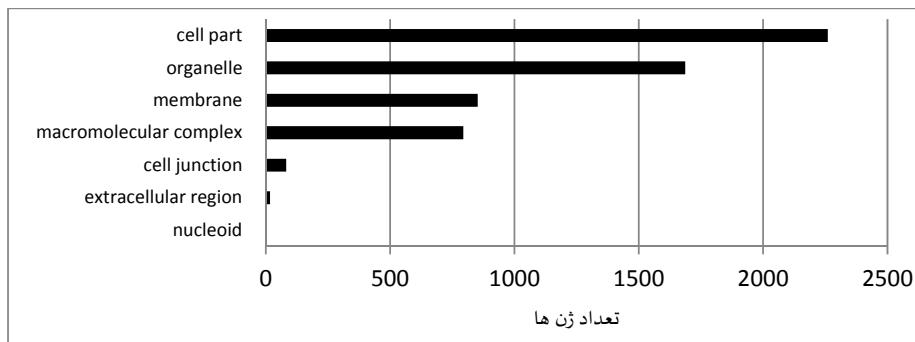
سپس به منظور جداسازی رونوشت دارای بیشترین بیان به ازای هر ژن، از ابزار filter_low_expr_transcripts استفاده کرده که در نتیجه فایل fasta با حجم ۶۵ مگابایت و دارای ۶۷۸۵۹ توالی منحصر به فرد با میزان N50 به طول ۱۰۲۱، میانگین ۶۸۳ bp و حداقل طول ۱۱۸۲۰ bp برای انجام آنالیز BLASTX ایجاد شد. پس از انجام تعداد ۴۵۴۳۹۹ خروجی برای ۲۴۸۸۷ رونوشت از مجموع ۶۷۸۵۹ عدد رونوشت اولیه توسط فرآیند BLASTX از میان پروتئینهای گیاه آراییدوپسیس تالیانا استخراج شد. سپس با استفاده از اسکریپت طراحی شده برای این پژوهش، معتبرترین نتایج براساس میزان امتیاز بالاتر و مقدار $E\text{-value} \leq 10^{-5}$ به ازای هر رونوشت جدا سازی گردید که شماره اختصاصی این پروتئینها در پایگاه داده آراییدوپسیس تالیانا، در فایل S2 ضمیمه شده است. بدین

براساس مشاهدات این تحقیق، Trinity و Oases-Velvet در K-mer های بزرگ‌تر عملکرد مناسب‌تری داشته و همان گونه که در جدول ۱ مشاهده می‌شود با افزایش مقدار K، میزان پوشش هم‌دیفی بالاتری برای خروجیهای این دو نرم‌افزار ایجاد گردیده است. به این صورت که از Oases-Velvet ۶۷/۷۱ درصد به ۷۲/۹۸ درصد و از SOAPdenovo-Trans در حالت K=32 نتایج مناسب‌تری تولید نمود (۴۴/۴۸ درصد و در K=32 نرخ هم‌دیفی به ۴۳/۵۶ درصد کاهش یافت).

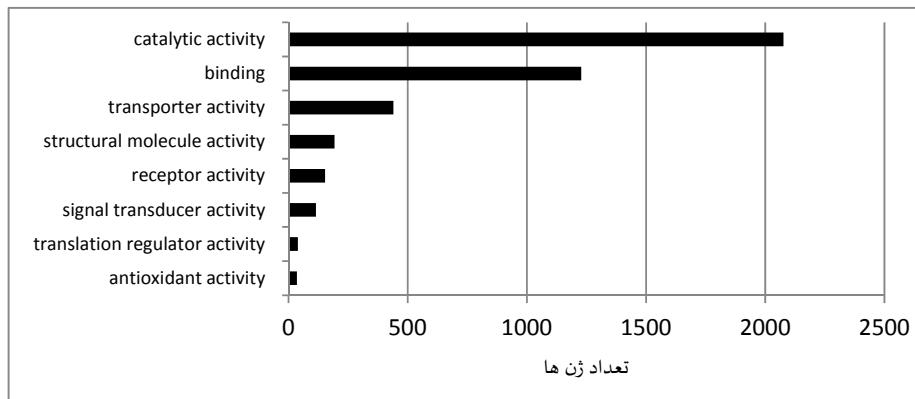
ابزار Trinity، نرم‌افزاری رایگان و متن‌باز بوده و از سه ماژول مختلف (Inchworm، Chrisalis و Butterfly) برای انجام فرآیند سرهمبندی استفاده کرده که این عمل از طریق: سرهمبندی خوانشها توالی‌بایی به صورت رونوشتها اولیه در Inchworm، دسته‌بندی این رونوشتها و تشکیل گراف دی‌بروین در Chrisalis و درنهایت پردازش گراف به منظور گزارش تمام رونوشتها با طول کامل و ایزوفرمهای حاصل از پیرایش ثانویه در Butterfly صورت می‌گیرد. فایل نهایی حاصل از سرهمبندی در قالب FASTA (.fa) و با اندازه تقریبی ۲۴۰ مگابایت؛ شامل ۶۷۸۵۹ و ۱۶۵۵۹۷ رونوشت با درصد ۴۲/۶۴ GC بود. میزان N50 نیز برای رونوشتها و ژنهای به ترتیب برابر با ۱۳۵۳ و ۱۶۴۷ بوده، همچنین اطلاعات آماری بیشتر در ارتباط با ترنسکریپتوم سرهمبندی شده در جدول ۲ قابل مشاهده است که با توجه به نرخ هم‌دیفی (Mapping)، (Jدول ۱) و اطلاعات آماری مناسب (Jدول ۲)، خروجی Trinity (K-mer=32) در وضعیت خوبی قرار داشته و نقطه شروع مناسبی برای آنالیزهای پایین دست می‌باشد. در ادامه با استفاده از ابزار RSEM فراوانی هریک از رونوشتها بر مبنای دو پارامتر TPM و FPKM محاسبه شد که نتایج این بررسی در فایل S1 ضمیمه شده است.

در شکل ۲ مشاهده می‌شود. خروجی نهایی بررسی GO در فایل S3 قرار دارد.

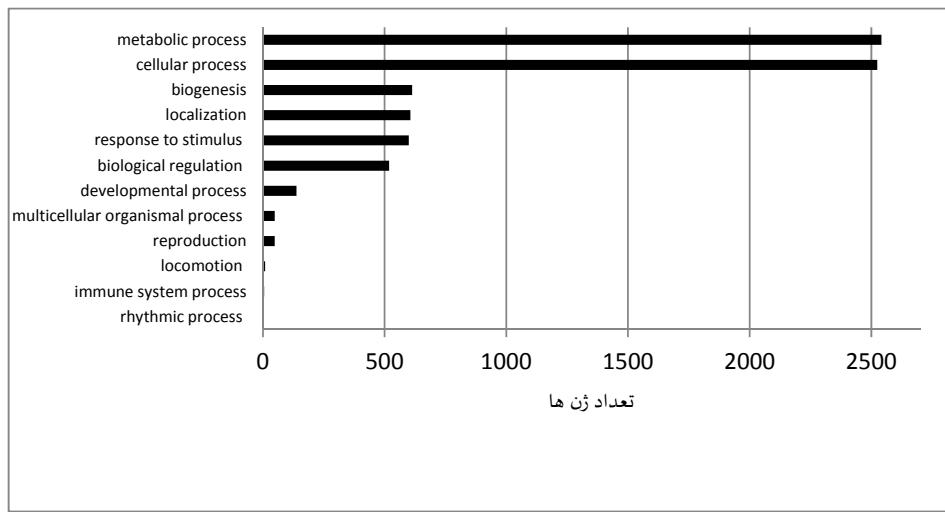
ترتیب فرآیند هستی‌شناسی با استفاده از ۲۴۸۸۷ نتیجه نهایی در ابزار PANTHER صورت گرفته و ۷۶۸۴ عدد پاسخ GO منحصر به فرد ثبت گردید که نتایج این بررسی



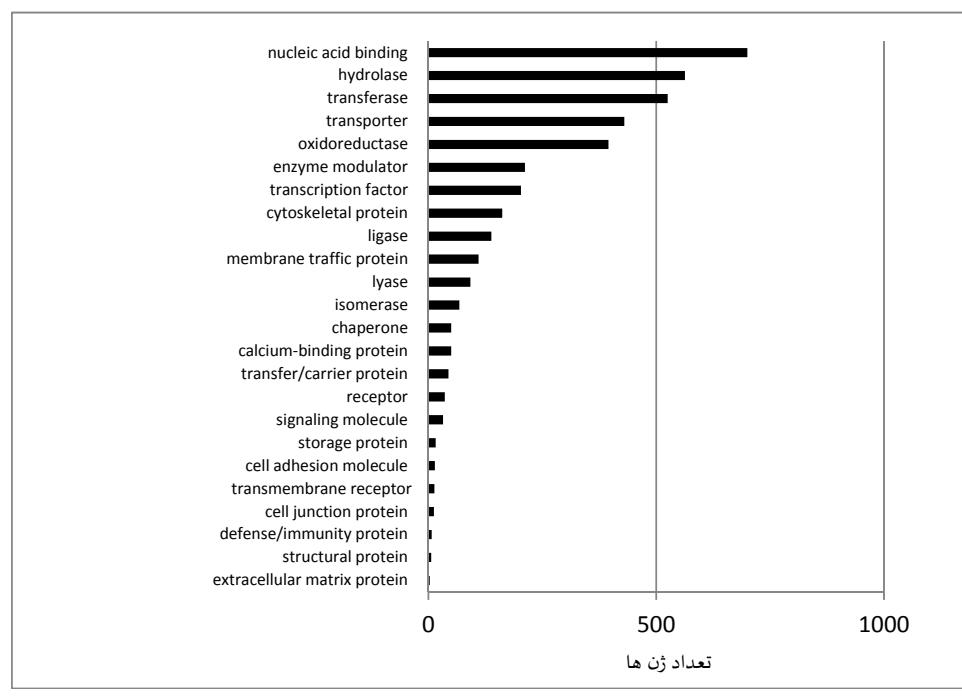
(Cellular Component)



(Molecular Function)



(Biological Process)



شکل ۲- نتایج هستی‌شناسی (GO) ۲۴۸۸۸ عدد از رونوشتاهای سرهمندی شده در سیستم PANTHER: اجزای تشکیل‌دهنده سلول (Cellular Component)، فعالیتهای مولکولی (Molecular Function) و نتایج حاصل از دسته‌بندی (Biological Process) پروتئینهای شناسایی شده

است که علاوه بر تشکیل ترنسکریپتها، می‌تواند توالیهای ایجاد شده و مشابه به هر یونی ژن را تحت عنوان یک ایزوفرم دسته‌بندی و مشخص نماید که این عمل تنها مخصوص به این نرمافزار بوده و برای بررسی میزان بیان ژنها و رونوشتاهای همچنین تغییرات ژنتیکی در محیط نرمافزاری مفید باشد. در ادامه فرآیند هستی‌شناسی در میان رونوشتاهای دارای بیشترین فراوانی نشان دهنده فعالیت بالای کاتالیتیک و حضور بسیار بالای پروتئینهای دخیل در اتصال و همچنین پروتئینهای دارای فعالیتهای آنتی اکسیدانی در میان فعالیتهای مولکولی این گیاه بوده و با توجه به دارویی بودن این گیاه و اهمیت متابولیتهای ثانویه در آن؛ از جمله متوكسی فلاون‌ها و رزمارینیک اسید (۱)، بیشترین فراوانی در بخش فرآیندهای زیستی با بیش از ۲۵۰۰ ژن (شکل ۲)، مربوط به فرآیندهای متابولیتی در این گیاه دارویی می‌باشد که با یافته‌های مشابه در گونه‌های نزدیک مطابقت دارد (۲ و ۲۶). کلاس‌بندی پروتئینهای

بحث

براساس نتایج این پژوهش خروجی scaffSeq از نرمافزار SOAPdenovo-Trans و خروجی transcripts از نرمافزار Trans-ABySS همچنین در نرمافزار Oases-Velvet دو فایل خروجی Transabyss.final و Transabyss.ref با توجه به پوشش بهتر و میزان N50 بالاتر نسبت به سایر خروجیها در وضعیت مناسب‌تری قرار دارند. از سوی دیگر با افزایش میزان *K* تغییرات محسوسی در نرخ هم‌دینی و پوشش خوانشها ایجاد شده که $K=32$ می‌تواند مقدار مناسبی برای انجام این دست پژوهشها به شمار آید. در نهایت می‌توان خروجی نرمافزار Trinity و همچنین Trans-ABySS از نرمافزار Transabyss.final گزینه برای انجام آنالیزهای پایین‌دست معرفی نمود. که با توجه به سرعت بالاتر و زمان کوتاه‌تر در نرمافزار Trans-ABySS، این مورد می‌تواند امتیاز دیگری برای آن محسوب شود. با این حال خروجی Trinity تنها موردی

پروفایل بیان این گیاه نیز، مستندسازی تمامی رونوشتها و بررسی میزان بیان برخی از فراوان ترین آنها توسط روشهای معمول آزمایشگاهی و مقایسه با روشهای نرم‌افزاری می‌تواند در یافتن مسیرهای متابولیتی با اهداف افزایش بیان متابولیت سودمند، راهگشای محققین و علاقه‌مندان قرار گیرد.

۲- میرزابی، س. (۱۳۹۶). پروفایل ترانسکریپtom نوک شاخه و ریشه گیاه سویا. مجله پژوهش‌های سلولی و مولکولی، ۴(۳۰)، ۴۹۹-۵۱۱.

- 3- Altschul SF, Madden TL, Schäffer AA, Zhang J, Zhang Z, Miller W, Lipman DJ (1997) Gapped BLAST and PSI-BLAST: a new generation of protein database search programs. *Nucleic Acids Res* 25(17):3389–3402
- 4- Amirghofran Z, Azadbakht M, Karimi MH (2000) Evaluation of the immunomodulatory effects of five herbal plants. *J Ethnopharmacol* 72(1):167–172
- 5- Blande D, Halimaa P, Tervahauta AI, Aarts MGM, Kärenlampi SO (2017) *De novo* transcriptome assemblies of four accessions of the metal hyperaccumulator plant *Noccaea caerulescens*. *Sci Data* 4:160131
- 6- Bolger AM, Lohse M, Usadel B (2014) Trimmomatic: a flexible trimmer for Illumina sequence data. *Bioinformatics* 30(15):2114–2120
- 7- Bräutigam A, Mullick T, Schliesky S, Weber APM (2011) Critical assessment of assembly strategies for non-model species mRNA-Seq data and application of next-generation sequencing to the comparison of C3 and C4 species. *J Exp Bot* 62(9):3093–3102
- 8- Chen S, Huang T, Zhou Y, Han Y, Xu M, Gu J (2017) AfterQC: automatic filtering, trimming, error removing and quality control for fastq data. *BMC Bioinformatics* 18(Suppl 3):80
- 9- Chopra R, Burow G, Farmer A, Mudge J, Simpson CE, Burow MD (2014) Comparisons of *de novo* transcriptome assemblers in diploid and polyploid species using peanut (*Arachis spp.*) RNA-seq data. *PLoS One* 9(12):e115055
- 10- Clarke K, Yang Y, Marsh R, Xie L, Zhang KK (2013) Comparative analysis of *de novo* transcriptome assembly. *Sci China Life Sci* 56(2):156
- 11- Duan J, Xia C, Zhao G, Jia J, Kong X (2012) Optimizing *de novo* common wheat transcriptome assembly using short-read RNA-Seq data. *BMC Genomics* 13(1):392
- 12- Fattahi M, Nazeri V, Torras-Claveria L, Sefidkon F, Cusido RM, Zamani Z, Palazon J (2013) Identification and quantification of leaf surface flavonoids in wild-growing populations of *Dracocephalum kotschy* by LC-DAD-ESI-MS. *Food Chem* 141(1):139–146
- 13- Flicek P, Birney E (2009) Sense from sequence reads: methods for alignment and assembly. *Nat Methods* 6:S6–S12
- 14- Grabherr MG, Haas BJ, Yassour M, et al (2011) Trinity: reconstructing a full-length transcriptome assembly without a genome from RNA-Seq data. *Nat Biotechnol* 29(7):644–652
- 15- Grabherr M, Haas BJ, Yassour M, et al (2011) Full-length transcriptome assembly from RNA-Seq data without a reference genome. *Nat Biotechnol* 29(7):644–52
- 16- Guo L, Allen KS, Deiulio G, Zhang Y, Madeiras AM, Wick RL, Ma L (2016) A *De Novo* -Assembly Based Data Analysis Pipeline for Plant Obligate Parasite Metatranscriptomic Studies. 7(July):1–9
- 17- Haas BJ, Papanicolaou A, Yassour M, et al (2013) *De novo* transcript sequence reconstruction from RNA-seq using the Trinity

شناسایی شده نیز حاکی از بیان بالای پروتئینهای ترانسفراز و اکسیدو ردوکتازها بوده که با توجه به استخراج نمونه اولیه از برگ گیاه توجیه می‌گردد. با این همه؛ توسعه و گسترش نرم‌افزارها و الگوریتمهای سرهمندی برای رسیدن به مسیر و ابزاری با قابلیت بسیار بالاتر و دقیق تر همچنان به عنوان یک چالش مهم در دنیای بیوانفورماتیک مطرح بوده و از سوی دیگر برای بررسی دقیق ژنها و

منابع

۱- ایوبی، ن.، حسینی، ب. و فتاحی، م. (۱۳۹۶). اثر القابی کیتوزان و کلشی‌سین بر تولید رزمارینیک اسید در ریشه مویین زرین گیاه (Dracocephalum kotschy Boiss). *مجله پژوهش‌های سلولی و مولکولی*، ۱(۳۰)، ۱۲۱-۱۳۰.

- platform for reference generation and analysis. *Nat Protoc* 8(8):1494–1512
- 18- Haas BJ, Papanicolaou A, Yassour M, et al (2013) *De novo* transcript sequence reconstruction from RNA-Seq: reference generation and analysis with Trinity. *Nat Protoc* 8(8):10.1038/nprot.2013.084
- 19- Haas BJ, Papanicolaou A, Yassour M, et al (2013) *De novo* transcript sequence reconstruction from RNA-seq using the Trinity platform for reference generation and analysis. *Nat Protoc* 8(8):1494–1512
- 20- Jalili A, Jamzad Z (1999) Red data book of Iran: A preliminary survey of endemic, rare and endangered plant species in Iran.
- 21- Javidnia K, Miri R, Kamalinejad M, Khoshneviszadeh M (2006) Constituents of the volatile oils of *Dracocephalum kotschy* Boiss. from Iran. *J Essent Oil Res* 18(3):342–344
- 22- Kamali M, Khosroyar S, Jalilvand MR (2014) Evaluation of phenolic, flavonoids, anthocyanin contents and antioxidant capacities of different extracts of aerial parts of *Dracocephalum kotschy*. *JN Khorasan Univ Med Sci* 6:627–634
- 23- Langmead B, Salzberg SL (2012) Fast gapped-read alignment with Bowtie 2. *Nat Methods* 9(4):357–359
- 24- Li B, Dewey CN (2011) RSEM: accurate transcript quantification from RNA-Seq data with or without a reference genome. *BMC Bioinformatics* 12(1):323
- 25- Li G, Du J, Li Y, Wu J (2015) Identification of putative olfactory genes from the oriental fruit moth grapholita molesta via an antennal transcriptome analysis. *PLoS One* 10(11):1–30
- 26- Li H, Fu Y, Sun H, Zhang Y, Lan X (2017) Transcriptomic analyses reveal biosynthetic genes related to rosmarinic acid in *Dracocephalum tanguticum*. *Sci Rep* 7(1):74
- 27- Mi H, Muruganujan A, Casagrande JT, Thomas PD (2013) Large-scale gene function analysis with the panther classification system. *Nat Protoc* 8(8):1551–1566
- 28- Miller JR, Koren S, Sutton G (2010) Assembly Algorithms for Next-Generation Sequencing Data. *Genomics* 95(6):315–327
- 29- Mizrahi E, Hefer CA, Ranik M, Joubert F, Myburg AA (2010) *De novo* assembled expressed gene catalog of a fast-growing Eucalyptus tree produced by Illumina mRNA-Seq.
- 30- Morozova O, Marra MA (2008) Applications of next-generation sequencing technologies in functional genomics. *Genomics* 92(5):255–264
- 31- Mozaffarian V (1996) A dictionary of Iranian plant names: Latin, English, Persian. Farhang Mo'aser
- 32- Rechinger KH (1982) *Salvia* in Flora Iranica, Labiateae, No. 150, edits. Rechinger KH Hedge IC, Akad. Druck Verlagsanstalt, Graz, Austria. , p 477
- 33- Ren X, Liu T, Dong J, Sun L, Yang J, Zhu Y, Jin Q (2012) Evaluating de Bruijn Graph Assemblers on 454 Transcriptomic Data. *PLoS One*. doi: 10.1371/journal.pone.0051188
- 34- Robertson G, Schein J, Chiu R, et al (2010) *De novo* assembly and analysis of RNA-seq data. *Nat Meth* 7(11):909–912
- 35- Schulz MH, Zerbino DR, Vingron M, Birney E (2012) Oases: robust *de novo* RNA-seq assembly across the dynamic range of expression levels. *Bioinformatics* 28(8):1086–1092
- 36- Sharafi A, Sohi HH, Azadi P, Sharafi AA (2014) Hairy root induction and plant regeneration of medicinal plant *Dracocephalum kotschy*. *Physiol Mol Biol Plants* 20(2):257–262
- 37- Tang Q, Ma X, Mo C, Wilson IW, Song C, Zhao H, Yang Y, Fu W, Qiu D (2011) An efficient approach to finding *Siraitia grosvenorii* triterpene biosynthetic genes by RNA-seq and digital gene expression analysis. *BMC Genomics* 12(1):343
- 38- Tao X, Gu Y-H, Wang H-Y, Zheng W, Li X, Zhao C-W, Zhang Y-Z (2012) Digital gene expression analysis based on integrated *de novo* transcriptome assembly of sweet potato [*Ipomoea batatas* (L.) Lam.]. *PLoS One* 7(4):e36234
- 39- Trapnell C, Salzberg SL (2009) How to map billions of short reads onto genomes. *Nat Biotechnol* 27(5):455–457
- 40- Wang Z, Gerstein M, Snyder M (2009) RNA-Seq: a revolutionary tool for transcriptomics. *Nat Rev Genet* 10(1):57–63
- 41- Wang S, Gribkov M (2016) Comprehensive evaluation of *de novo* transcriptome assembly programs and their effects on differential gene expression analysis. *Bioinformatics* 215:btw625
- 42- Xie Y, Wu G, Tang J, et al (2014) SOAPdenovo-Trans: *de novo* transcriptome assembly with short RNA-Seq reads. *Bioinformatics* 30(12):1660–1666

- 43- Xu D-L, Long H, Liang J-J, Zhang J, Chen X, Li J-L, Pan Z-F, Deng G-B, Yu M-Q (2012) *De novo* assembly and characterization of the root transcriptome of *Aegilops variabilis* during an interaction with the cereal cyst nematode. *BMC Genomics* 13(1):133
- 44- Yaghmai MS, Taffazoli R (1988) The essential oil of *Dracocephalum kotschy* Boiss. Flavour Fragr J 3(1):33–36
- 45- Zerbino DR, Birney E (2008) Velvet: algorithms for *de novo* short read assembly using de Bruijn graphs. *Genome Res* 18(5):821–829
- 46- Zhao Q-Y, Wang Y, Kong Y-M, Luo D, Li X, Hao P (2011) Optimizing *de novo* transcriptome assembly from short-read RNA-Seq data: a comparative study. *BMC Bioinformatics* 12(14):S2
- 47- ZHAO L, Zachary L-R, CHEN S-Y, GUO Z-H (2012) comparing *De Novo* Transcriptome Assemblers Using Illumina RNA-Seq Reads. *Plant Divers Resour* 34(5):487
- 48- NCBI database search. <https://www.ncbi.nlm.nih.gov/gquery/?term=Dracocephalum+kotschy>.

The Comparison of Assembly Softwares and Gene Ontology Analysis using transcriptome sequencing data from *Dracocephalum kotschy* Boiss.

Poursalavati A.N.¹, Ebrahimi A.² and Rashidi monfared S.¹

¹ Dept. of Agricultural Biotechnology, Tarbiat Modares University, Tehran, I.R. of Iran.

² Dept. of Agronomy, Faculty of Agriculture, Shahrood Univwrsity of Technology, Shahrood, I.R. of Iran.

Abstract

With fast advances in next generation sequencing technologies, they have become powerful and low-cost tools for transcriptome studies. Nowadays; *de novo* assembly of transcriptome data, has caused the formation of the new pathway in the study of non-model genome species. With the expansion of this technology and increasing the number of assembly softwares, choosing the best software for assembling transcriptome sequencing data has become a challenge for biologists. For the first time in this study, we used transcriptome sequencing data of *Dracocephalum kotschy* in order to reach the appropriate parameters and superior software; so here we used Oases-velvet, SOAPdenovo-Trans, Trans-ABySS and Trinity softwares with two different values of K parameter; $K=25$ and $K=32$. The results of assembly by each software were compared to others in the term of several criteria. The result suggests the superiority of Trinity and Trans-ABySS softwares. Finally, the output of the best assembly was used to estimate abundance of various isoforms and Gene Ontology analysis as regards to the pharmaceutical properties of this plant and the high amount of secondary metabolites, the highest frequency of sections in the biological processes was related to the metabolic activity.

Key words: Trinity, SOAPdenovo-Trans, Oases-velvet, Trans-ABySS, Gene Ontology