



پیش بینی آسیب DNA و کیفیت جنین در لقاح مصنوعی بر مبنای داده های مرکز رویان با استفاده از تکنیک های هوش مصنوعی

لاله آرمی<sup>۱</sup>، روشنگ رضائی\*<sup>۲</sup>، محمدنوبد بقولی زاده<sup>۳</sup>

<sup>۱</sup> دانشجوی دکتری، گروه مهندسی کامپیوتر، دانشکده مهندسی برق و کامپیوتر، دانشگاه کاشان، کاشان، ایران، laleharmi93@gmail.com

\*<sup>۲</sup>مدیرعامل شرکت مهندسی داده پردازان اندیشه نوین آناهیتا، rr28960@gmail.com

<sup>۳</sup>محمدنوبد بقولی زاده، n.baghoulizadeh@gmail.com

#### چکیده

لقاح مصنوعی یک تکنیک پر کاربرد در پزشکی تولید مثل است، اما پیش بینی کیفیت جنین و شناسایی آسیب های احتمالی DNA چالشی در این فرآیند است. برای رفع این مشکل، محققان از الگوریتم های هوش مصنوعی استفاده کرده اند تا مدل هایی توسعه دهند که کیفیت جنین را پیش بینی و آسیب DNA را تشخیص دهند. با استفاده از تکنیک های یادگیری ماشین، این مدل ها می توانند الگوها و همبستگی هایی را جهت شناسایی آسیب دیدگی DNA و کیفیت جنین شناسایی کنند و پیش بینی هایی در مورد کیفیت جنین و آسیب DNA ایجاد کنند و به پزشکان اجازه دهند تدابیر مناسبی را برای کاهش آسیب DNA و افزایش کیفیت جنین اتخاذ کنند و با تصمیمات آگاهانه، شانس یک نتیجه موفقیت آمیز را بهینه کنند. در این چالش بر اساس داده های دریافت شده از مرکز رویان سعی در پیش بینی آسیب DNA بر اساس ارزیابی نمونه اسپرم، سن مردان و همچنین پیش بینی نتایج لقاح، کیفیت جنین و حاملگی زوجین با استفاده از نتایج آسیب DNA در قالب دو زیر مساله مطرح شده را داریم که با توجه به تکنیک ها و روش های در حوزه هوش مصنوعی مسائل این چالش را پوشش خواهیم داد.

کلید واژه ها: آسیب DNA، حاملگی زوجین، دابوست، رگرسیون جنگل تصادفی



### ۱- مقدمه

لقاح مصنوعی یک تکنیک رایج در پزشکی تولید مثل برای تسهیل لقاح است. با این حال، یکی از چالش‌های تلقیح مصنوعی، پیش‌بینی کیفیت جنین و شناسایی آسیب‌های احتمالی DNA است که می‌تواند بر موفقیت این روش تأثیر زیادی بگذارد. یکی از مشکلات شایع در فرایند لقاح مصنوعی، آسیب دیدگی دی ان ای و کیفیت جنین است که می‌تواند تأثیری مهم بر موفقیت و نتیجه حاصل از لقاح داشته باشد. در حال حاضر، شناخت دقیقی از عوامل تأثیرگذار و میزان تأثیر آن‌ها بر آسیب دی ان ای و کیفیت جنین وجود ندارد که موجب کاهش اطمینان و قابلیت پیش‌بینی نتیجه لقاح می‌شود.

برای رفع این مشکل، محققان به الگوریتم‌های هوش مصنوعی<sup>۱</sup> روی آورده‌اند تا مدل‌هایی را توسعه دهند که می‌توانند کیفیت جنین را به‌طور دقیق پیش‌بینی کنند و آسیب DNA را تشخیص دهند. این مدل‌ها از مجموعه داده‌های بزرگ از چرخه‌های لقاح مصنوعی قبلی، از جمله اطلاعات مربوط به بیماران، کیفیت اسپرم و تخمک و جنین‌های حاصل استفاده می‌کنند.

با استفاده از تکنیک‌های یادگیری ماشین، این مدل‌های هوش مصنوعی می‌توانند حجم وسیعی از داده‌های جمع‌آوری شده از فرایند لقاح مصنوعی را تجزیه و تحلیل کنند و الگوها و همبستگی‌هایی را جهت بررسی آسیب دیدگی دی ان ای و کیفیت جنین شناسایی کنند که تشخیص آن‌ها برای انسان دشوار است. سپس این مدل‌ها می‌توانند پیش‌بینی‌هایی در مورد کیفیت جنین و آسیب DNA ایجاد کنند و به پزشکان اجازه می‌دهند تدابیر مناسبی را برای کاهش آسیب دی ان ای و افزایش کیفیت جنین اتخاذ کنند و با تصمیمات آگاهانه، شانس یک نتیجه موفقیت‌آمیز را بهینه کنند.

به‌طور کلی، ادغام هوش مصنوعی در لقاح مصنوعی پتانسیل ایجاد انقلابی در زمینه پزشکی تولید مثل را دارد. با استفاده از قدرت یادگیری ماشینی، پزشکان می‌توانند میزان موفقیت روش‌های لقاح مصنوعی را بهبود بخشند و مراقبت‌های کارآمدتر و شخصی‌تر را به بیماران ارائه دهند. با این حال، تحقیقات و اعتبار سنجی بیشتر برای اطمینان از صحت و قابلیت اطمینان این مدل‌های هوش مصنوعی قبل از اجرای گسترده در عمل بالینی ضروری است.

ساختار این مقاله به شرح زیر است، در بخش دوم مروری بر ادبیات خواهیم داشت در بخش سوم روش‌های پایه و اولیه که برای حل دو زیرمسئله بوده است معرفی می‌گردد. در بخش چهارم به معرفی روش استفاده شده برای دو زیرمسئله پرداخته و نتایج هر یک را در زیر بخش خودش نشان داده است و در بخش نهایی به بررسی و جمع‌بندی می‌پردازیم.

### ۲- مروری بر روی ادبیات تحقیق

تحقیقات در زمینه پیش‌بینی آسیب DNA و کیفیت جنین در لقاح مصنوعی با استفاده از هوش مصنوعی به منظور بهبود فرایند لقاح مصنوعی و کاهش خطرات آن انجام شده است. این تحقیقات به دنبال استفاده از الگوریتم‌ها و مدل‌های هوش مصنوعی مانند شبکه‌های عصبی و الگوریتم ژنتیک برای پیش‌بینی عملکرد لقاح مصنوعی و کیفیت جنین است. یکی از موضوعات مهم در این تحقیقات، پیش‌بینی آسیب DNA است.

اعتبارسنجی الگوریتم‌ها بر روی داده‌های آزمایشگاهی و نتایج واقعی جمع‌آوری شده از بیماران می‌تواند به محققان کمک کند تا الگوهای مشخصی را برای تشخیص و پیش‌بینی آسیب DNA ان‌ای تعریف کنند. از این طریق می‌توانند به موقع اطلاع داشته باشند که کدام بیماران بیشترین خطر بروز آسیب دی ان ای را دارند و اقدامات مناسب جلوگیری از آسیب دی ان ای را انجام دهند. علاوه بر آن، تحقیقات در زمینه پیش‌بینی کیفیت جنین نیز انجام می‌شود. با استفاده از داده‌های جمع‌آوری شده از بیماران و تکنیک‌های هوش مصنوعی، می‌توان الگوها و روش‌هایی را برای تشخیص جنین‌های با کیفیت بالا و کاهش احتمال جنین‌های ناسالم تعریف کرد. این الگوها و روش‌ها به پزشکان در تصمیم‌گیری در مورد انتخاب جنین بهتر و کاهش خطرات مربوط به لقاح مصنوعی کمک می‌کنند.

چندین مطالعه نتایج امیدوارکننده‌ای را در استفاده از هوش مصنوعی برای پیش‌بینی کیفیت جنین و آسیب DNA نشان داده‌اند. به عنوان مثال، یک مطالعه از الگوریتم‌های یادگیری عمیق برای پیش‌بینی کیفیت جنین بر اساس پارامترهای متعدد، مانند ویژگی‌های مورفولوژیکی و اطلاعات ژنتیکی استفاده کرد. این مدل به دقت بالایی در پیش‌بینی احتمال لانه‌گزینی جنین و موفقیت بارداری دست یافت.

مطالعه دیگری از هوش مصنوعی برای تشخیص آسیب DNA در نمونه‌های اسپرم استفاده کرد. با تجزیه و تحلیل تصاویر سلول‌های اسپرم، این مدل توانست میزان تکه‌تکه شدن DNA را که با رشد ضعیف جنین و کاهش باروری مرتبط است، تعیین کند. این اطلاعات می‌تواند به پزشکان کمک کند تا بهترین نمونه‌های اسپرم را برای لقاح مصنوعی انتخاب کنند. به‌طور کلی، تحقیقات در زمینه استفاده از هوش مصنوعی در پیش‌بینی آسیب دی ان ای و کیفیت جنین در لقاح مصنوعی به منظور بهبود نتایج این فرایند و کاهش خطرات آن صورت می‌گیرد. این تحقیقات می‌توانند به محققان و پزشکان در انتخاب بهتر جنین و پیش‌بینی موارد ناسازگاری به آنها کمک کنند.

### ۳- پیش‌نیازها

در این بخش به‌طور مختصر به روش‌ها و تکنیک‌های یادگیری ماشین پرداخته شده تا زمینه‌های لازم برای روش پیشنهادی فراهم شود.

#### ۳-۱- روش‌های برای تخمین داده‌های ناموجود

در بسیاری از مجموعه داده‌ها، داده‌هایی که برای یک یا چند ویژگی موجود نیستند یا به عبارت دیگر داده‌های گم‌شده، مشکلاتی را ایجاد می‌کنند. این داده‌های گم‌شده می‌توانند باعث کاهش دقت و کارایی مدل‌های یادگیری ماشین شوند و باعث تحلیل نادرست داده‌ها و انجام پیش‌بینی‌های ناصحیح شوند [1-3]. برای این منظور، تخمین داده‌های گم‌شده و پر کردن آن‌ها با مقادیر تخمین زده شده، بهبود دقت و کارایی مدل‌های یادگیری ماشین و تحلیل دقیق‌تر داده‌ها کمک می‌کند و همچنین جلوگیری از بروز خطاهای غیرمنتظره و افزایش دقت تحلیل‌های می‌شود. از جمله روش‌های که برای تخمین داده‌های ناموجود به کار برده می‌شود می‌توان به KNN Imputation

<sup>1</sup> Artificial intelligence (AI)



### ۳-۲- روش‌های مبتنی بر یادگیری مرکب

استفاده از یادگیری مرکب در حوزه یادگیری ماشین از طبیعت انسان برای تصمیم‌گیری‌های مهم الهام گرفته است، به این صورت که نظرات افراد مختلف پرسیده شده و برای نظرات آن‌ها، وزنی در نظر گرفته می‌شود. سپس نظرات با قاعده خاصی ترکیب شده تا تصمیم معقول اتخاذ شود. یادگیری مرکب رویکردی جهت بهبود عملکرد در طبقه‌بندی است [12-14].

### ۳-۲-۱- روش آدابوست

الگوریتم آدابوست، یک روش یادگیری مرکب است و معروف‌ترین الگوریتم از خانواده الگوریتم‌های تقویتی است که توسط یو فروند و رابرت شاپیر ارائه شده است [15]. در روش آدابوست، طبقه‌بندی‌کننده هر مرحله جدید به نفع نمونه‌های غلط طبقه‌بندی شده در مراحل قبل تنظیم می‌گردد. به عبارت دیگر، در هر تکرار، تمرکز طبقه‌بند مربوطه بیشتر بر تشخیص نمونه‌هایی است که به اشتباه توسط طبقه‌بندهای مراحل قبل برچسب گذاری شده اند. طبقه‌بندی پایه که در اینجا استفاده می‌شود فقط کفایت از طبقه‌بندی تصادفی (۵۰٪) بهتر باشد؛ و به این ترتیب بهبود عملکرد الگوریتم با تکرارهای بیشتر بهبود می‌یابد. روند کلی این الگوریتم به این صورت است که تعداد زیادی طبقه‌بندی پایه که طبقه‌بندی بهتری ارائه نموده اند را تشویق کرده و وزن بیشتری به آن طبقه‌بندی اختصاص می‌دهد. همچنین به طبقه‌بندی بدتر ارائه شده وزن کمتری اختصاص می‌دهد.

### ۳-۲-۲- رگرسیون جنگل تصادفی

RandomForestRegressor یک الگوریتم یادگیری ماشین است که برای مسائل پیش‌بینی و رگرسیون استفاده می‌شود. این الگوریتم از مجموعه‌ای از درخت‌های تصمیم استفاده می‌کند تا مدلی قوی و پایدار برای پیش‌بینی مقادیر عددی ایجاد کند [16-19]. روش RandomForestRegressor از تکنیک تصادفی جهت داده‌ها (Random Forest) استفاده می‌کند که با انتخاب تصادفی زیرمجموعه‌هایی از داده‌ها و ساخت درخت‌های تصمیم مستقل، مدلی قوی و انعطاف‌پذیر ایجاد می‌کند. سپس با میانگین‌گیری از پیش‌بینی‌های تمام درخت‌ها، مقدار نهایی پیش‌بینی شده را تولید می‌کند. این الگوریتم از ویژگی‌های مختلف داده‌ها برای ساختن درخت‌های تصمیم استفاده می‌کند و به این ترتیب می‌تواند با داده‌های پرت و نویزی نیز مقاوم باشد. همچنین این الگوریتم از روش تقویت‌کننده یادگیری ماشین استفاده می‌کند که باعث می‌شود مدل نهایی بسیار قوی و دقیق باشد. این الگوریتم به دلیل اینکه از ترکیب چندین درخت تصمیم استفاده می‌کند، دارای انعطاف‌پذیری بالا و مقاومت در برابر بیش‌برازش<sup>۳</sup> است. همچنین، این الگوریتم می‌تواند با داده‌های بزرگ و با ابعاد بالا نیز مقابله کند و به خوبی عملکرد کند.

### ۳-۲-۳- اختلاط خبره‌ها بر پایه‌ی ماشین یادگیری سریع با شبکه

#### میانجی آموزش پذیر

در [20,21] روش اختلاط خبره مبتنی بر ELM با شبکه میانجی آموزش پذیر که به اختصار MEETG نامیده شده است. روش MEETG یک روش

[4,5], Denoise Autoencoder [6]. تجزیه ماتریس غیرمنفی [7,8] و

غیره اشاره نمود [9-11].

۱- پر کردن مقدار گم‌شده با استفاده از KNN:

KNN Imputation یا پر کردن مقدار گم‌شده با استفاده از k-nearest neighbors یک تکنیک است که برای پر کردن مقادیر گم‌شده در یک مجموعه داده با تخمین آن‌ها بر اساس ویژگی‌های داده‌های نزدیک مشابه استفاده می‌شود. این روش به ویژه برای مجموعه داده‌هایی با تعداد کمی مقادیر گم‌شده مؤثر است و زمانی کارایی دارد که مقادیر گم‌شده به صورت تصادفی پخش شده باشند. این روش با پیدا کردن k نزدیک‌ترین نقاط داده (همسایه‌های نزدیک) به مشاهده با مقدار گم‌شده کار می‌کند و سپس با استفاده از مقادیر مشخص شده آن‌ها، مقدار گم‌شده را تخمین می‌زند. پس از شناسایی همسایه‌های نزدیک، با استفاده از مقادیر شناخته شده آن‌ها برای ویژگی گم‌شده، مقدار ناموجود تخمین زده می‌شود. برای تخمین مقدار گم‌شده می‌توان از میانگین، مد، یا میانگین وزنی مقادیر شناخته شده از همسایه‌های نزدیک استفاده کرد.

۲- دی‌نویز اتوانکودر:

Denoise Autoencoder یک تکنیک یادگیری عمیق است که برای پر کردن مقادیر گم‌شده با آموزش یک شبکه عصبی برای بازسازی داده ورودی با مقادیر گم‌شده استفاده می‌شود. این روش با یادگیری الگوها و ارتباطات پایه‌ای در داده‌ها برای پر کردن مقادیر گم‌شده کارایی دارد. این روش برای مجموعه داده‌هایی با تعداد زیادی مقادیر گم‌شده مؤثر است و می‌تواند الگوهای پیچیده در داده‌ها را مدیریت کند. اتوانکودر برای کمینه کردن تفاوت بین داده ورودی و داده بازسازی شده آموزش داده می‌شود و به این ترتیب می‌آموزد که با توجه به الگوهای یادگرفته شده، مقادیر گم‌شده را پر کند.

۳ تجزیه ماتریس غیرمنفی:

تجزیه ماتریس، به ویژه تجزیه ماتریس غیرمنفی<sup>۲</sup>، یک تکنیک کاهش ابعاد است که همچنین برای برآورد مقادیر گم‌شده استفاده می‌شود. این روش با تجزیه ماتریس اصلی داده به دو ماتریس کم‌ابعاد که ویژگی‌های پنهان داده را ضبط می‌کنند کار می‌کند. این روش برای مجموعه داده‌هایی با تعداد زیادی مقادیر گم‌شده مؤثر است و می‌تواند روابط غیرخطی در داده‌ها را مدیریت کند. هدف NMF پیدا کردن دو ماتریس غیر منفی است که حاصل ضرب آن‌ها به داده اصلی نزدیک باشد و به این ترتیب ساختار پنهان داده را در داده‌ها ضبط کرده و مقادیر گم‌شده را بر اساس این ساختار پنهان پر می‌کند.

لازم به ذکر است که روش KNN Imputation مناسب برای مجموعه داده‌هایی با تعداد کمی مقادیر گم‌شده است و زمانی کارایی دارد که مقادیر گم‌شده به صورت تصادفی پخش شده باشند. دی‌نویز اتوانکودر برای مجموعه داده‌هایی با تعداد زیادی مقادیر گم‌شده مؤثر است و می‌تواند الگوهای پیچیده در داده‌ها را مدیریت کند. تجزیه ماتریس NMF برای مجموعه داده‌هایی با تعداد زیادی مقادیر گم‌شده مؤثر است و می‌تواند روابط غیرخطی در داده‌ها را مدیریت کند. هر یک از این متدها دارای قدرتها و مزایا مختلفی هستند و می‌توانند براساس ویژگی‌ها و نیازهای خاص مجموعه داده انتخاب شوند.

<sup>2</sup> Negative Matrix Factorization (NMF)

<sup>3</sup> overfitting

یادگیری مرکب است که بر اساس ترکیبی از خبره‌ها برای بهبود هزینه محاسبه و تسریع فرایند یادگیری ME عمل می‌نماید. یادگیری مرکب رویکردی است که توانایی بالایی در بهبود دقت طبقه‌بندی کلی دارد. روش MEETG از مزایای ME و ELM استفاده می‌کند در معماری این روش متشکل از چندین متخصص و یک شبکه میانی است فضای ورودی مسئله تجزیه می‌شود و کارشناسان با مدیریت شبکه میانی به فضاهای فرعی مختلف اختصاص می‌یابند. این روش در یک دور آموزش می‌بیند و نیاز به آموزش مکرر و تکراری نیست بنابراین فرآیند یادگیری بسیار سریع‌تر و توانایی تعمیم بهتر را در مقایسه با سایر الگوریتم‌های یادگیری سنتی ارائه می‌کند [22,23].

#### ۴-روش پیشنهادی

برای دو مساله‌های مطرح شده با توجه به دیتاست دریافتی ( داده‌های مرکز رویان) که این داده‌ها برخی ناموجود بودن که لازم است یک پیش‌پردازشی روی داده‌ها انجام شد. ما در این چالش با توجه به میحث بخش سوم اشاره کردیم از روش KNN Imputation برای تخمین داده‌های ناموجود استفاده نموده‌ایم. این روش مناسب برای مجموعه داده‌هایی با تعداد کمی مقادیر گم‌شده است و زمانی کارایی دارد که مقادیر گم‌شده به صورت تصادفی پخش شده باشند.

#### ۴-۱- پیش‌بینی آسیب DNA با استفاده از ارزیابی نمونه اسپرم و

##### سن مردان


در این مساله هدف پیش‌بینی ویژگی‌های HDS، satability، SCSAassay و TUNELassay که نشان دهنده آسیب DNA هستند می‌باشد. برای این قسمت از چالش از روش RandomForestRegressor برای پیش‌بینی آسیب DNA استفاده نمودیم و معیار MSE را مدل ارزیابی خود انتخاب نمودیم.

MSE به معنای میانگین مربعات خطا<sup>۴</sup> است و یک معیار اندازه‌گیری خطا در مدل‌های پیش‌بینی و تخمین است. این معیار برای اندازه‌گیری فاصله بین مقادیر پیش‌بینی شده توسط یک مدل و مقادیر واقعی داده‌ها استفاده می‌شود. MSE برابر با جمع مربعات اختلاف بین مقادیر پیش‌بینی شده و مقادیر واقعی


داده‌ها است و با کاهش این مقدار، دقت و عملکرد مدل بهبود می‌یابد.

در پارت اول دیتاستی با ۱۷۶ نمونه و ۱۳ ویژگی و ۳ ویژگی به عنوان هدف دریافت شده است که برای آموزش مدل استفاده شده است. ما برای آموزش و همچنین تنظیم پارامترهای مدل خود از این دیتا دریافت شده آن را به ۹۰٪ نمونه‌های آموزش، و ۱۰٪ دیگر را برای نمونه‌های ارزیابی تقسیم نمودیم.

خروجی نتایج در مرحله اول با میانگین مربع خطا برابر با ۱۲.۷ که نمودار خروجی‌های تست در مرحله اول در شکل ۱ نمایش داده شده است. در ادامه، بعد از در اختیار گرفتن داده‌های تست که شامل نمونه ۷۶ می‌باشد را روی مدل ذخیره شده خود اجرا گرفتیم.



شکل ۱: ماتریس درهم‌ریختگی برای پیش‌بینی حاملگی مثبت و منفی



#### ۴-۲- پیش‌بینی پیش‌بینی نتایج لقاح، کیفیت جنین، و حاملگی

##### زوجین با استفاده از نتایج آسیب DNA

در این چالش ابتدا با استفاده از KNN Imputation برای تخمین داده‌های ناموجود استفاده نموده‌ایم. سپس بعد از تقسیم نمودن به داده‌های آموزشی و تست برای پیش‌بینی سه ویژگی of.emabryo.with.gradA، of.emabryo.with.gradB و of.emabryo.with.gradC از روش RandomForestRegressor استفاده نموده و از تقسیم مقادیر بدست آمده به Total.number.of.embryos برای ویژگی‌های Percent.of.emabryo.with.gradA، with.gradB و with.gradC انجام داده‌ایم و برای پیش‌بینی حاملگی مثبت و عدد دو نشانگر حاملگی منفی از طبقه‌بندهای مرکب همچون آداپوست و MEETG استفاده شده است که خروجی‌های هر دو مدل یکسان بوده است.

روش فوق برای دیتاست آموزش که در اختیار قرار گرفته شده که شامل ۷۰ نمونه بوده است را ۲۱ نمونه را برای تست اختصاص داده‌ایم. در ادامه نتایج

<sup>4</sup> Mean squared error



حاصل که به صورت ماتریس درهم‌ریختگی در شکل ۳ نمایش داده شده است. با استفاده از ماتریس درهم‌ریختگی انواع معیارهای Recall, Precision, Accuracy و f1-score را محاسبه نمود

		برجسب پیشبینی شده		
		۲	۴	۲
برجسب واقعی	۲	۴	۲	
	۲	۲	۱۳	

شکل ۳: ماتریس درهم‌ریختگی برای پیش‌بینی حاملگی مثبت و منفی

در ادامه برای نمونه‌های تست که در گام دوم دریافت شده را روی مدل آموزش دیده اجرا نمودیم.

#### ۵- نتیجه‌گیری

با توجه به نتایج حاصل از این مقاله، می‌توان نتیجه‌گیری کرد که استفاده از تکنیک‌های هوش مصنوعی برای پیش‌بینی آسیب DNA و کیفیت جنین در لقاح مصنوعی، می‌تواند بهبود قابل توجهی در عملکرد و دقت پیش‌بینی داشته باشد. این روش می‌تواند به عنوان یک ابزار موثر برای کمک به پزشکان و متخصصان در انجام لقاح مصنوعی و پیش‌بینی موفقیت آن، مورد استفاده قرار گیرد. این مقاله نشان دهنده اهمیت و کارایی تکنیک‌های هوش مصنوعی در پیش‌بینی و تخمین داده‌های پزشکی است و می‌تواند به توسعه روش‌های بهبود یافته در این زمینه کمک کند.

#### منابع

- Armina, Roslan, et al. "A review on missing value estimation using imputation algorithm." *Journal of Physics: Conference Series*. Vol. 892. No. 1. IOP Publishing, 2017.
- Troyanskaya, Olga, et al. "Missing value estimation methods for DNA microarrays." *Bioinformatics* 17.6 (2001): 520-525.
- Choong, Miew Keen, Maurice Charbit, and Hong Yan. "Autoregressive-model-based missing value estimation for DNA microarray time series data." *IEEE Transactions on information technology in biomedicine* 13.1 (2009): 131-137.
- Keerin, Phimmarin, and Tossapon Boongoen. "Improved knn imputation for missing values in gene expression data." *Computers, Materials and Continua* 70.2 (2021): 4009-4025.
- Abnane, Ibtissam, et al. "Analogy software effort estimation using ensemble KNN imputation." 2019 45th Euromicro Conference on Software Engineering and Advanced Applications (SEAA). IEEE, 2019.
- Boquet, Guillem, et al. "Missing data in traffic estimation: A variational autoencoder imputation method." *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2019
- Li, Yifeng, and Alioune Ngom. "The non-negative matrix factorization toolbox for biological data mining." *Source code for biology and medicine* 8.1 (2013): 1-15.
- He, Xiangnan, et al. "Fast matrix factorization with nonuniform weights on missing data." *IEEE transactions on neural networks and learning systems* 31.8 (2019): 2791-2804.
- Alonso, Sergio, et al. "A learning procedure to estimate missing values in fuzzy preference relations based on additive consistency." *Modeling Decisions for Artificial Intelligence: First International Conference, MDAI 2004, Barcelona, Spain, August 2-4, 2004. Proceedings 1*. Springer Berlin Heidelberg, 2004.
- Leke, Collins, and Tshilidzi Marwala. "Missing data estimation in high-dimensional datasets: A swarm intelligence-deep neural network approach." *Advances in Swarm Intelligence: 7th International Conference, ICSI 2016, Bali, Indonesia, June 25-30, 2016, Proceedings, Part I 7*. Springer International Publishing, 2016.
- Kim, Hyunsoo, Gene H. Golub, and Haesun Park. "Missing value estimation for DNA microarray gene expression data: local least squares imputation." *Bioinformatics* 21.2 (2005): 187-198.
- Bloch, Isabelle. "Information combination operators for data fusion: A comparative review with classification." *IEEE Transactions on systems, man, and cybernetics-Part A: systems and humans* 26.1 (1996): 52-67.
- Polikar, Robi. "Ensemble based systems in decision making." *IEEE Circuits and systems magazine* 6.3 (2006): 21-45.
- Zhang, Cha, and Yunqian Ma, eds. *Ensemble machine learning: methods and applications*. Springer Science & Business Media, 2012.
- Freund, Yoav, and Robert E. Schapire. "A decision-theoretic generalization of on-line learning and an application to boosting." *European conference on computational learning theory*. Berlin, Heidelberg: Springer Berlin Heidelberg, 1995.
- Nakashima, Hayato, Ismail Arai, and Kazutoshi Fujikawa. "Passenger counter based on random forest regressor using drive recorder and sensors in buses." 2019 IEEE International Conference on Pervasive Computing and Communications Workshops (PerCom Workshops). IEEE, 2019.
- You, Dongfang, et al. "Identification of genetic features associated with fine particulate matter (PM<sub>2.5</sub>) modulated DNA damage using improved random forest analysis." *Gene* 740 (2020): 144570.
- Graw, J. H., W. T. Wood, and B. J. Phrampus. "Predicting global marine sediment density using the random forest regressor machine learning algorithm." *Journal of Geophysical Research: Solid Earth* 126.1 (2021): e2020JB020135.
- El Mrabet, Zakaria, et al. "Random Forest regressor-based approach for detecting fault location and duration in power systems." *Sensors* 22.2 (2022): 458.
- Armi, Laleh, Elham Abbasi, and Jamal Zarepour-Ahmadabadi. "Mixture of ELM based experts with trainable gating network." *arXiv preprint arXiv:2105.11706* (2021).
- Armi, Laleh, Elham Abbasi, and Jamal Zarepour-Ahmadabadi. "Texture images classification using improved local quinary pattern and mixture of ELM-based experts." *Neural Computing and Applications* (2021): 1-24.
- Armi, Laleh, and Hossein Ebrahimpour-Komleh. "Classification of Skin Cancer With Using Color-ILQP and MEETG." 2023 6th International Conference on Pattern Recognition and Image Analysis (IPRIA). IEEE, 2023.
- Armi, Laleh, and Elham Abbasi. "Tree Bark Classification using Color-improved Local Quinary Pattern and Stacked MEETG." *Journal of AI and Data Mining* 11.3 (2023): 391-405.