



## بررسی عوامل مشارکت در انتخابات‌های جمهوری اسلامی ایران، با استفاده از الگوریتم‌های یادگیری عمیق و تکنیک‌های یادگیری گروهی

سجاد نیکخو، میلاد فریدنیا، کرم الله باقری فرد<sup>۳</sup>

### چکیده:

مشارکت سیاسی به‌ویژه مشارکت در انتخابات یکی از مولفه‌های کلیدی در فرآیندهای دموکراتیک است که تحت تأثیر مجموعه‌ای از عوامل اجتماعی، اقتصادی و روان‌شناختی قرار دارد. در این تحقیق، به تحلیل و پیش‌بینی میزان مشارکت در انتخابات جمهوری اسلامی ایران با استفاده از مجموعه داده‌های حاصل از یک نظرسنجی عمومی پرداخته شده است. این مجموعه داده شامل ۱۰۰۰۰ رکورد از ویژگی‌های فردی و اجتماعی نظیر جنسیت، سن، سطح تحصیلات، وضعیت اقتصادی، شغلی و تعاملات رسانه‌ای می‌باشد. برای انجام تحلیل‌های پیش‌بینی، از مدل‌های پیشرفته یادگیری عمیق (شبکه‌های عصبی) و تکنیک‌های یادگیری گروهی مانند درختان تصادفی و تقویتی گرادینان بهره گرفته شده است. نتایج تجربی این تحقیق نشان می‌دهند که تحصیلات، درآمد ماهانه، باورهای سیاسی، تعاملات رسانه‌ای و سطح اعتماد به نظام سیاسی به‌طور معناداری بر تصمیم‌گیری افراد برای مشارکت در انتخابات تأثیر می‌گذارند. علاوه بر این، دقت مدل‌های یادگیری ماشین در پیش‌بینی مشارکت، با استفاده از ویژگی‌های اجتماعی و اقتصادی به میزان قابل توجهی افزایش یافته است. این تحقیق می‌تواند ابزار مفیدی برای تحلیلگران و طراحان سیاست‌های انتخاباتی باشد و به آن‌ها کمک کند تا استراتژی‌های موثرتری برای افزایش مشارکت و بهبود دقت پیش‌بینی‌های انتخاباتی اتخاذ کنند. همچنین، یافته‌های این مطالعه می‌تواند زمینه‌ساز مطالعات آینده در زمینه شبیه‌سازی و پیش‌بینی رفتارهای انتخاباتی باشد.

**واژگان اصلی:** مشارکت انتخاباتی، عوامل اجتماعی، یادگیری عمیق، یادگیری گروهی، تحلیل داده‌های اجتماعی.

۱. استادیار گروه معارف اسلامی دانشگاه فرهنگیان، تهران، ایران (نویسنده مسئول) nikkhoo313@yahoo.com

۲. دانشجوی دکتری، گروه مهندسی کامپیوتر، دانشگاه آزاد اسلامی، یاسوج، ایران

۳. استادیار، گروه مهندسی کامپیوتر، دانشگاه آزاد اسلامی، یاسوج، ایران

## ۱- مقدمه

مشارکت سیاسی، به‌ویژه شرکت در انتخابات، یکی از ارکان بنیادین هر نظام دموکراتیک است که نشان‌دهنده عمق مشروعیت و میزان تعامل میان دولت و شهروندان است. این مشارکت نه تنها به‌عنوان یک شاخص کلیدی در سنجش کارآمدی نهادهای سیاسی شناخته می‌شود، بلکه بازتاب‌دهنده تعاملات پیچیده اجتماعی، اقتصادی و فرهنگی در جامعه نیز محسوب می‌شود. در جمهوری اسلامی ایران، مشارکت در انتخابات همواره یکی از مسائل محوری و مورد توجه سیاست‌گذاران، محققان و فعالان اجتماعی بوده است. تحلیل و پیش‌بینی این مشارکت می‌تواند به درک بهتر رفتار انتخاباتی، شناسایی عوامل موثر بر آن، و در نهایت بهبود فرآیندهای تصمیم‌گیری سیاسی کمک کند.

در دهه‌های اخیر، پیشرفت‌های سریع در علوم داده و هوش مصنوعی، فرصت‌های بی‌ظیری برای تحلیل و مدل‌سازی پدیده‌های اجتماعی فراهم کرده است. استفاده از روش‌های یادگیری عمیق<sup>۱</sup> و تکنیک‌های یادگیری گروهی<sup>۲</sup> به‌طور خاص امکان تحلیل دقیق‌تر داده‌های پیچیده و بزرگ را فراهم کرده و درک عمیق‌تری از روابط میان متغیرهای مختلف به‌دست می‌دهد. این روش‌ها با قدرت شناسایی الگوهای پنهان در داده‌ها و توانایی پیش‌بینی دقیق، جایگاه ویژه‌ای در تحقیقات علوم اجتماعی و سیاسی یافته‌اند.

با وجود پژوهش‌های گسترده‌ای که تاکنون در زمینه عوامل مؤثر بر مشارکت سیاسی در ایران و جهان انجام شده است، بسیاری از این مطالعات به روش‌های سنتی تحلیل داده‌ها متکی بوده‌اند و کمتر به بهره‌گیری از روش‌های نوین هوش مصنوعی و یادگیری ماشین پرداخته‌اند. این پژوهش تلاش دارد با استفاده از داده‌های اجتماعی و سیاسی جمع‌آوری شده از جامعه ایران، از تکنیک‌های یادگیری عمیق و یادگیری گروهی برای پیش‌بینی مشارکت در انتخابات بهره‌گیرد. در این راستا، مجموعه داده‌های دقیقی شامل متغیرهای متعددی نظیر وضعیت اقتصادی، تحصیلات، جنسیت، باورهای سیاسی، و میزان دسترسی به منابع اطلاعاتی تهیه شده و مورد تحلیل قرار گرفته است.

اهداف این پژوهش چندوجهی است. نخست، شناسایی دقیق‌ترین مدل برای پیش‌بینی رفتار مشارکتی در انتخابات است. دوم، بررسی تأثیر متغیرهای اجتماعی و سیاسی بر رفتار انتخاباتی

1. Deep Learning

2. Ensemble Learning

شهروندان و ارائه بیش‌هایی برای سیاست‌گذاران و تصمیم‌گیرندگان است. سوم، ارائه چارچوبی کاربردی برای بهره‌گیری از تکنیک‌های هوش مصنوعی در مطالعات علوم اجتماعی و سیاسی است که می‌تواند در سایر زمینه‌های پژوهشی نیز مورد استفاده قرار گیرد.

به‌طور کلی، این مقاله در نظر دارد با ترکیب قدرت تحلیل داده‌های بزرگ با روش‌های پیشرفته یادگیری ماشین، به‌ویژه یادگیری عمیق، به نتایجی دست یابد که علاوه بر پیش‌بینی دقیق، زمینه‌ساز درک عمیق‌تر پویایی‌های اجتماعی و سیاسی در ایران باشد. پیش‌بینی مشارکت در انتخابات نه تنها یک تمرین علمی، بلکه ابزاری عملی برای بهبود سیاست‌گذاری‌ها و استراتژی‌های ارتباطی در نظام‌های سیاسی است. این پژوهش، با اتکا به مجموعه داده‌های دقیق و استفاده از پیشرفته‌ترین روش‌های مدل‌سازی، می‌کوشد تا گامی مهم در این زمینه بردارد و الگویی برای تحقیقات آینده ارائه کند.

## ۲- مرور ادبیات و پیشینه پژوهش

مشارکت در انتخابات و تحلیل عوامل مؤثر بر آن همواره موضوعی مهم در تحقیقات علوم سیاسی و جامعه‌شناسی بوده است. پژوهش‌ها نشان می‌دهند که میزان مشارکت انتخاباتی می‌تواند تحت تأثیر مجموعه‌ای از عوامل اجتماعی، اقتصادی، فرهنگی و سیاسی قرار گیرد. به‌طور خاص، پیش‌بینی مشارکت در انتخابات با استفاده از روش‌های نوین تحلیل داده‌ها، از جمله یادگیری ماشین و یادگیری عمیق، توجه زیادی را به خود جلب کرده است. در این بخش، مرور ادبیاتی از پژوهش‌های داخلی و خارجی که به تحلیل و پیش‌بینی مشارکت انتخاباتی پرداخته‌اند، آورده شده است.

تحلیل عوامل اجتماعی و فرهنگی مؤثر بر مشارکت در انتخابات:

این مطالعه که بر جوامع روستایی شهرستان لنجان تمرکز دارد، نشان می‌دهد که عوامل اجتماعی مانند سطح تحصیلات، مشارکت در فعالیت‌های اجتماعی و نقش ریش‌سفیدان می‌توانند تأثیر بسزایی در افزایش مشارکت انتخاباتی داشته باشند. به‌ویژه تأکید شده است که وجود تعاملات اجتماعی مثبت در این مناطق، انگیزه‌های مشارکت را افزایش می‌دهد (نوروزی، ۱۴۰۳).

دینداری و رفتار انتخاباتی جوانان:

مطالعه‌ای جامعه‌شناختی بر روی جوانان شهر زنجان نشان داده است که دینداری، به‌عنوان یکی از عوامل فرهنگی، تأثیر مستقیمی بر میزان مشارکت در انتخابات دارد. نتایج این پژوهش نشان می‌دهد که جوانانی که اعتقادات مذهبی قوی‌تری دارند، با احتمال بیشتری در انتخابات

شرکت می‌کنند (کرمی و همکاران، ۱۴۰۱).

نقش اعتماد اجتماعی در رفتار انتخاباتی:

این پژوهش به بررسی رابطه بین اعتماد به نظام سیاسی و میزان مشارکت شهروندان در انتخابات ریاست‌جمهوری و مجلس پرداخته است. یافته‌ها حاکی از آن است که کاهش اعتماد اجتماعی منجر به افت نرخ مشارکت می‌شود (مسعودنیا و رهبر قاضی، ۱۳۹۵).

تأثیر رسانه‌های اجتماعی بر مشارکت انتخاباتی:

این پژوهش، با تأکید بر نقش رسانه‌های اجتماعی و فضای مجازی، نشان داده است که شبکه‌های اجتماعی به‌عنوان بستری برای ترویج اطلاعات انتخاباتی و تشویق شهروندان به مشارکت، اهمیت قابل‌توجهی دارند (رضایی، ۱۴۰۰).

در سطح جهانی، مطالعات زیادی در زمینه تحلیل و پیش‌بینی مشارکت انتخاباتی با استفاده از مدل‌های مختلف داده‌کاوی انجام شده است. یکی از اولین مطالعات در این زمینه توسط لازرا<sup>۱</sup> ارائه شد که به بررسی عواملی چون سطح تحصیلات، وضعیت اقتصادی، سن، جنسیت و تأثیر رسانه‌ها بر مشارکت انتخاباتی پرداخته بودند. این مطالعه نشان داد که ترکیب این متغیرها می‌تواند به‌طور مؤثر میزان مشارکت را پیش‌بینی کند. این تحقیق به‌ویژه بر تأثیر رسانه‌های اجتماعی بر مشارکت نسل جدید در انتخابات تأکید کرد (Lazer, 2020).

در یک تحقیق دیگر بیکر<sup>۲</sup> از مدل‌های یادگیری ماشین برای شبیه‌سازی مشارکت انتخاباتی استفاده کردند. آن‌ها از الگوریتم‌های ماشین بردار پشتیبان<sup>۳</sup> و جنگل تصادفی<sup>۴</sup> برای تحلیل مجموعه داده‌های اجتماعی و اقتصادی استفاده کردند و دریافتند که مدل‌های یادگیری ماشین می‌توانند پیش‌بینی‌های دقیق‌تری از میزان مشارکت داشته باشند. به‌ویژه، آن‌ها نشان دادند که مدل‌های یادگیری ماشین توانایی بیشتری در تشخیص الگوهای پیچیده و تأثیرات غیرمستقیم عوامل مختلف دارند (Baker, 2019).

در مطالعه‌ای دیگر بیرگرن و لافارتی<sup>۵</sup> به بررسی تأثیر احساسات عمومی و اعتماد به دولت بر

1 . Lazer

2 . Baker

3 . Support Vector Machine(SVM)

4 . Random Forest

5 . Berggren & Lafferty

مشارکت در انتخابات پرداخته‌اند. این مطالعه نشان داد که اعتماد عمومی به نهادهای دولتی و احساسات مثبت نسبت به فرآیند انتخابات، تأثیر زیادی بر میزان مشارکت دارد. این یافته‌ها در بسیاری از کشورهای دموکراتیک به اثبات رسید و درک جدیدی از نقش «اعتماد» در رفتار انتخاباتی ارائه داد (Berggren & Lafferty, 2021).

شمولی نیز با استفاده از روش‌های پیشرفته تحلیل داده‌ها و یادگیری ماشین، به تحلیل تأثیرات متغیرهای اجتماعی-اقتصادی بر مشارکت انتخاباتی در کشورهای مختلف پرداختند. این مطالعه به ویژه بر نحوه استفاده از داده‌های عظیم و مدل‌های پیچیده یادگیری ماشین تأکید کرد و به این نتیجه رسید که استفاده از داده‌های بزرگ و تحلیل آن‌ها می‌تواند به شبیه‌سازی و پیش‌بینی دقیق‌تری از مشارکت در انتخابات منجر شود (Shmueli and Others, 2023).

با توجه به گسترش فناوری‌های داده‌کاوی و یادگیری ماشین، اخیراً توجه زیادی به استفاده از این تکنیک‌ها در تحلیل رفتارهای اجتماعی و پیش‌بینی‌های انتخاباتی معطوف شده است. در یک مطالعه دیگر، پیرا از روش‌های یادگیری عمیق برای تحلیل مشارکت انتخاباتی در برزیل استفاده کردند. این مطالعه به ویژه نشان داد که مدل‌های یادگیری عمیق، به‌ویژه شبکه‌های عصبی مصنوعی، می‌توانند به‌طور مؤثری به شبیه‌سازی و پیش‌بینی مشارکت در انتخابات بپردازند و با دقت بالا الگوهای پیچیده اجتماعی را شبیه‌سازی کنند (Pereira and Others, 2020).

### ۳- روش‌شناسی پژوهشی

روش‌شناسی این پژوهش شامل مراحل طراحی، جمع‌آوری داده، پیش‌پردازش، انتخاب مدل، آموزش مدل، و ارزیابی مدل است. در ادامه، هر یک از مراحل با جزئیات توضیح داده می‌شود. همچنین، فرمول‌ها و مفاهیم ریاضی مربوطه برای شفاف‌سازی روش‌ها ارائه شده است.

#### ۳،۱ جمع‌آوری داده

برای این پژوهش، مجموعه داده‌ای شامل اطلاعات اجتماعی، اقتصادی و سیاسی شهروندان طی یک مطالعه میدانی از عموم مردم جمع‌آوری گردیده است. این مجموعه داده شامل متغیرهایی نظیر سن، جنسیت، سطح تحصیلات، وضعیت شغلی، درآمد ماهانه، باورهای سیاسی، میزان

<sup>1</sup> . Shmueli et al

<sup>2</sup> . Pereira et al

دسترسی به منابع اطلاعاتی و رسانه‌ها، و میزان مشارکت در فعالیت‌های اجتماعی بود. داده‌ها از طریق پرسشنامه‌های استاندارد به دست آمد.

### ۲,۳. پیش‌پردازش داده‌ها

پیش‌پردازش داده‌ها مرحله‌ای حیاتی در تحلیل داده‌های خام است. این مرحله شامل موارد زیر بود:

#### ✓ پاک‌سازی داده‌ها:

- حذف داده‌های گمشده یا مقادیر پرت.
- جایگزینی مقادیر گمشده با میانگین یا میانه.

#### ✓ نرمال‌سازی داده‌ها: برای اطمینان از همگن بودن مقیاس متغیرها، نرمال‌سازی داده‌ها با

استفاده از روش Min-Max انجام شد:

$$X' = \frac{X - X_{\min}}{X_{\max} - X_{\min}}$$

که  $X'$  مقدار مقیاس‌بندی شده،  $X_{\min}$  حداقل مقدار و  $X_{\max}$  حداکثر مقدار ویژگی است. این روش به ویژه برای الگوریتم‌هایی که به فاصله‌های مطلق حساس هستند، مانند الگوریتم‌های مبتنی بر فاصله، مناسب است.

این تکنیک به تضمین این که تمام ویژگی‌ها به طور یکنواخت در مدل مشارکت دارند، کمک می‌کند و از بروز مشکلاتی نظیر تسلط ویژگی‌های با مقیاس بزرگ‌تر بر مدل جلوگیری می‌کند. با نرمال‌سازی و مقیاس‌بندی داده‌ها، عملکرد مدل‌های یادگیری ماشین بهبود می‌یابد و دقت پیش‌بینی‌ها افزایش می‌یابد.

### ۳,۳. رمزگذاری متغیرهای گسسته

رمزگذاری متغیرهای گسسته یکی از مراحل مهم در پیش‌پردازش داده‌ها است که به تبدیل داده‌های دسته‌بندی‌شده به قالب‌های قابل استفاده برای مدل‌های یادگیری ماشین کمک می‌کند. این مرحله به مدل‌ها اجازه می‌دهد تا به طور موثر از اطلاعات موجود در متغیرهای گسسته استفاده کنند. برای ورود داده‌ها به مدل پژوهش نیاز است که عملیات رمزگذاری متغیرهای گسسته انجام گیرد. دو رویکرد زیر برای انجام این عملیات مورد استفاده قرار می‌گیرند:

<sup>1</sup> . <https://survey.porsline.ir/s/G9gkErQa>

رمزگذاری برچسب<sup>۱</sup>: از رمزگذاری برچسب برای متغیرهای دسته بندی باینری استفاده می شود. در این روش، هر دسته از یک متغیر گسسته به یک عدد صحیح یکتا تخصیص داده می شود. این روش برای متغیرهایی که دارای ترتیب ذاتی هستند، مناسب است.

رمزگذاری تک حالتی: برای جلوگیری از معرفی روابط ترتیبی، برای متغیرهای طبقه بندی شده با بیش از دو دسته، از کدگذاری تک حالتی استفاده می شود. در این روش، هر دسته از یک متغیر گسسته به یک بردار باینری تخصیص داده می شود که تنها یک عنصر از آن برابر با ۱ و بقیه عناصر برابر با ۰ هستند. این روش برای متغیرهایی که دارای ترتیب نیستند، مناسب است.

این روش‌ها به مدل‌های یادگیری ماشین کمک می کنند تا بتوانند به طور موثری از اطلاعات موجود در متغیرهای گسسته استفاده کنند. با استفاده از این روش‌ها، عملکرد مدل‌ها بهبود می یابد و دقت پیش‌بینی‌ها افزایش می یابد.

### ۴.۳. بررسی متعادل بودن داده

بررسی متعادل بودن داده یکی از مراحل مهم در پیش پردازش داده‌ها است که به تضمین توزیع یکنواخت کلاس‌ها در داده‌ها کمک می کند. عدم تعادل کلاس‌ها می تواند به کاهش دقت مدل‌های یادگیری ماشین منجر شود. مراحل اصلی در بررسی و مدیریت داده‌های نامتعادل شامل موارد زیر است:

تجزیه و تحلیل توزیع متغیر هدف: ابتدا باید توزیع متغیر هدف (مثلاً برچسب‌ها) بررسی شود تا نسبت کلاس‌های مختلف مشخص شود. این کار معمولاً با استفاده از نمودارهای فراوانی یا هیستوگرام‌ها انجام می شود.

استفاده از تکنیک‌های نمونه‌گیری مجدد:

تکنیک نمونه‌برداری بیش از حد: این تکنیک شامل افزایش تعداد نمونه‌های کلاس اقلیت از طریق تکثیر آنها یا ایجاد نمونه‌های مصنوعی است. یکی از روش‌های معروف در این زمینه تکنیک نمونه‌برداری بیش از حد اقلیت مصنوعی<sup>۲</sup> است. در این روش، نمونه‌های جدیدی از کلاس اقلیت با ایجاد ترکیبی از نمونه‌های موجود ساخته می شوند. روش نمونه‌برداری بیش از حد

<sup>1</sup> Label Encoding

<sup>2</sup> One Hot Encoding

<sup>3</sup> Oversampling

<sup>4</sup> Synthetic Minority Over-sampling Technique (Smote)

اقلیت مصنوعی به جای نمونه‌برداری تکراری از نمونه‌های موجود، با استفاده از ترکیب خطی نزدیک‌ترین همسایگان نمونه‌های جدید را ایجاد می‌کند.

$$X_{new} = X_i + \lambda \cdot (X_{nn} - X_i)$$

در این فرمول  $X_{new}$  نمونه جدید،  $X_i$  نمونه اصلی از کلاس اقلیت،  $X_{nn}$  یکی از نزدیک‌ترین همسایگان  $X_i$  و  $\lambda$  یک عدد تصادفی بین ۰ و ۱ که تعیین‌کننده محل دقیق نمونه جدید بین  $X_i$  و  $X_{nn}$  است.

تکنیک کم نمونه‌گیری<sup>۱</sup> این تکنیک شامل کاهش تعداد نمونه‌های کلاس اکثریت است تا تعادل بین کلاس‌ها ایجاد شود. این روش می‌تواند اطلاعات موجود در کلاس اکثریت را کاهش دهد و باید با احتیاط استفاده شود.

### ۵.۳. تشخیص و مدیریت داده‌های پرت

نقاط پرت نقاط داده‌ای هستند که به طور قابل توجهی با سایر مشاهدات در یک مجموعه داده متفاوت است. تشخیص و رسیدگی به موارد پرت در مدل‌سازی پیش‌بینی‌کننده مهم است، زیرا می‌توانند تحلیل‌ها و مدل‌های آماری را منحرف کنند.

روش‌های تشخیص شامل موارد زیر است:

روش امتیاز  $Z$ : در این روش مقادیر پرت با اندازه‌گیری تعداد انحرافات استاندارد یک نقطه داده از میانگین مجموعه داده شناسایی می‌شود. نقاط داده با امتیاز  $Z$  بیشتر از ۳ یا کمتر از -۳ معمولاً نقاط پرت در نظر گرفته می‌شوند.

روش  $IQR$ : روش محدوده بین ربعی ( $IQR$ ) شامل محاسبه  $IQR$  است که تفاوت بین صدک ۷۵ و صدک ۲۵ است. نقاط پرت به عنوان نقاط داده زیر  $Q1 - 1.5IQR$  یا بالاتر از  $Q3 + 1.5IQR$  شناسایی می‌شوند.

### ۶.۳. جدا کردن داده‌های آموزش و آزمون با روش اعتبارسنجی متقابل $K$ -تایی طبقاتی<sup>۴</sup>

اعتبارسنجی متقابل  $K$ -تایی طبقاتی یک روش آماری پیشرفته در یادگیری ماشین است که به

<sup>1</sup> Undersampling

<sup>2</sup>  $Q3$

<sup>3</sup>  $Q1$

<sup>4</sup> Stratified K-fold Cross-Validation

ارزیابی دقیق‌تر و متعادل‌تر عملکرد مدل‌ها کمک می‌کند. این روش به ویژه برای داده‌های نامتوازن که توزیع دسته‌ها نابرابر است، کاربرد دارد.

در اعتبارسنجی متقابل  $K$ -تایی طبقاتی، داده‌ها به گونه‌ای تقسیم می‌شوند که نسبت هر کلاس در هر یک از زیرمجموعه‌ها (تاش‌ها) مشابه نسبت آن کلاس در کل مجموعه داده باشد. این روش تضمین می‌کند که هر تاش نماینده مناسبی از کل داده‌ها است و از مشکلاتی مانند بایس‌ناشی از تقسیم‌بندی نامتوازن جلوگیری می‌کند.

اعتبارسنجی متقابل  $K$ -تایی طبقاتی شامل مراحل زیر می‌باشد:

✓ **تقسیم داده‌ها به تاش‌ها**: مجموعه داده  $D$  به طور تصادفی به  $k$  زیرمجموعه مساوی،  $D_1, D_2, \dots, D_k$  تقسیم می‌شود، به طوری که نسبت هر کلاس در هر زیرمجموعه مشابه نسبت آن کلاس در کل داده باشد.

✓ **آموزش و اعتبارسنجی**: برای  $i \in \{1, 2, \dots, k\}$

○ مدل بر روی داده‌ها به جز تاش  $i$  آموزش داده می‌شود.

○ مدل بر روی  $D_i$  اعتبارسنجی می‌شود.

✓ **جمع‌آوری عملکرد**: معیار عملکرد (مانند دقت، صحت، فراخوان) برای هر یک از  $k$

تاش محاسبه می‌شود و نتایج به‌طور میانگین محاسبه می‌شوند تا یک تخمین عملکرد

واحد ارائه شود.

### ۷.۳. انتخاب ویژگی

انتخاب ویژگی‌ها یک فرآیند بحرانی در یادگیری ماشین و تجزیه و تحلیل داده است که شامل انتخاب زیرمجموعه‌ای از ویژگی‌های مرتبط (متغیرها، پیش‌بیننده‌ها) برای استفاده در ساخت مدل می‌شود. اهداف اصلی انتخاب ویژگی‌ها بهبود عملکرد مدل‌های پیش‌بینی، کاهش اورفیتینگ و کاهش هزینه‌های محاسباتی است.

انتخاب ویژگی‌ها با حذف ویژگی‌های بی‌ربط یا تکراری که به قدرت پیش‌بینی مدل کمک نمی‌کنند، عملکرد مدل را بهبود می‌بخشد. این کاهش در تعداد ویژگی‌ها همچنین می‌تواند در کاهش مشکل ابعاد کمک کند و به مدل‌های قابل تعمیم منجر شود. علاوه بر این، انتخاب

<sup>1</sup> Bias

ویژگی‌ها مدل‌ها را ساده‌تر می‌کند، آن‌ها را سریع‌تر آموزش می‌دهد و در تفسیر آن‌ها کمک می‌کند، که به ویژه در مواجهه با مجموعه داده‌های بزرگ مفید است.

### • روش‌های فیلتر<sup>۱</sup>

این روش‌ها معمولاً در مرحله پیش‌پردازش استفاده می‌شوند. روش‌های فیلتر، ارتباط ویژگی‌ها را با بررسی ویژگی‌های ذاتی آنها، مستقل از هر الگوریتم یادگیری، ارزیابی می‌کنند. آنها از نظر محاسباتی کارآمد هستند و می‌توانند به عنوان یک مرحله پیش‌پردازش قبل از آموزش مدل استفاده شوند.

ضرایب همبستگی برای ویژگی‌های عددی:

همبستگی پیرسون: رابطه خطی بین دو متغیر را اندازه‌گیری می‌کند. بدون نیاز به الگوریتم یادگیری ماشین، ویژگی‌ها را از مجموعه داده انتخاب می‌کند و از آن برای خلاصه‌سازی قدرت رابطه خطی بین دو متغیر داده‌ای استفاده می‌شود. این ضریب می‌تواند بین ۱- (همبستگی منفی کامل) تا ۱ (همبستگی مثبت کامل) متغیر باشد. روش‌های فیلتری برای شناسایی سریع ویژگی‌های مرتبط مفید هستند، اما به عملکرد مدل توجه نمی‌کنند.

$$r_{xy} = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2} \sqrt{\sum (y_i - \bar{y})^2}}$$

که در این فرمول ضریب همبستگی پیرسون بین متغیرهای  $X$  و  $Y$  و مقدار متغیر  $X$  برای مشاهده  $i$ -ام،  $y_i$  مقدار متغیر  $Y$  برای مشاهده  $i$ -ام،  $\bar{x}$  میانگین نمونه متغیر  $X$  که به عنوان میانگین تمام مقادیر  $X_i$  محاسبه می‌شود و  $\bar{y}$  میانگین نمونه متغیر  $Y$  که به عنوان میانگین تمام مقادیر  $Y_i$  محاسبه می‌شود و  $\sum$  نماد جمع، نشان دهنده مجموع تمام مشاهدات  $i$ -ام می‌باشد. مقدار مطلق بالای  $r_{xy}$  نشان دهنده یک رابطه خطی قوی است.

تست مربع چي برای ویژگی‌های گسسته:

آزمون مربع چي استقلال دو متغیر دسته‌ای را ارزیابی می‌کند. میزان آماری آزمون مربع چي بالا نشان دهنده رابطه معنادار بین ویژگی و هدف است.

فرمول:

<sup>1</sup> Filter Methods

<sup>2</sup> Correlation Coefficients

<sup>3</sup> Chi-Square Test

$$X^2 = \sum \frac{(O_i - E_i)^2}{F}$$

که در این فرمول  $X^2$  آماره آزمون چي برای استقلال،  $O_i$  فرکانس مشاهده شده در دسته  $i$ -ام و  $E_i$  فراوانی مورد انتظار در رده  $i$  تحت فرضیه صفر استقلال می باشد.

#### • روش های بسته بندی<sup>۱</sup>

در این روش با آموزش یک مدل و ارزیابی عملکرد آن، زیر مجموعه های ویژگی را ارزیابی می کنند. این روش ها از نظر محاسباتی فشرده هستند، اما اغلب منجر به انتخاب زیرمجموعه های ویژگی های بهتری می شوند که متناسب با مدل خاص هستند .  
این روش ها شامل:

انتخاب رو به جلو: بدون هیچ ویژگی شروع می شود و ویژگی ها را یکی یکی اضافه می کند و ویژگی هایی را انتخاب می کند که عملکرد مدل را در هر مرحله بیشتر بهبود می بخشد.  
حذف به عقب: با تمام ویژگی ها شروع می شود و در هر مرحله کمترین ویژگی را حذف می کند.  
حذف ویژگی بازگشتی (RFE): به صورت تکراری مدل ها را می سازد و کم اهمیت ترین ویژگی را حذف می کند تا زمانی که به تعداد مطلوب ویژگی ها برسد .

#### • روش های تعبیه شده<sup>۲</sup>

روش های تعبیه شده انتخاب ویژگی را در طول فرآیند آموزش مدل انجام می دهند. آنها معمولاً کارآمدتر از روش های بسته بندی هستند زیرا انتخاب ویژگی را در ساخت مدل ادغام می کنند.  
این روش ها شامل:

الف: رگرسیون کمند<sup>۳</sup> (L1) و لبه<sup>۴</sup> (L2):

رگرسیون کمند: یک جریمه L1 را به تابع ضرر اضافه می کند و باعث افزایش پراکندگی می شود که فرمول زیر بیانگر آن می باشد.

<sup>1</sup> Wrapper Methods

<sup>2</sup> Forward Selection

<sup>3</sup> Backward Elimination

<sup>4</sup> Recursive Feature Elimination

<sup>5</sup> Embedded Methods

<sup>6</sup> Lasso

<sup>7</sup> Ridge

$$\text{Lasso Loss Function} = \sum (y_i - \hat{y}_i)^2 + \lambda \sum |w_i|$$

رگرسیون لبه: یک جریمه  $L_2$  به تابع ضرر اضافه می‌کند و ضرایب کوچک را اثربخش می‌کند که فرمول زیر بیانگر آن می‌باشد.

$$\text{Ridge Loss Function} = \sum (y_i - \hat{y}_i)^2 + \lambda \sum w_i^2$$

که در اینجا  $y_i$  مقدار پاسخ واقعی برای مشاهده  $i$ -ام و  $\hat{y}_i$  مقدار پاسخ پیش بینی شده برای مشاهده  $i$ -ام،  $\lambda$  پارامتر کنترل کننده قدرت منظم سازی و  $w_i$  ضریب رگرسیون مرتبط با متغیر پیش بینی  $i$ -ام است.

ب: روش های مبتنی بر درخت:

جنگل تصادفی: از امتیازهای اهمیت ویژگی به دست آمده از درختان تصمیم استفاده می‌کند. اهمیت معمولاً با میانگین کاهش ناخالصی<sup>۲</sup> یا اهمیت جینی اندازه گیری می‌شود:

$$\text{GiniImportance}(f) = \sum \frac{p(t) \Delta \text{Gini}(t, f)}{|T|}$$

که در فرمول (۷-۲) اهمیت جینی ( $f$ ) برابر با اهمیت ویژگی  $f$  در جنگل تصادفی بر اساس ناخالصی جینی،  $t$  شاخص درخت در جنگل تصادفی  $T$ ،  $p_t$  نسبت نمونه‌ها در گره  $t$ ،  $\Delta \text{Gini}(t, f)$  تغییر در ناخالصی جینی هنگام تقسیم بر روی ویژگی  $f$  در گره  $t$  و  $T$  تعداد کل درختان در جنگل تصادفی می‌باشد.

تقویت گرادیان<sup>۳</sup>: شبیه به جنگل تصادفی است، اما از تقویت برای بهبود دقت استفاده می‌کند

۸.۳. معیار های ارزیابی مدل

برای تحلیل کارایی مدل های مورد استفاده در پژوهش از معیار های ارزیابی دقت<sup>۴</sup>، و امتیاز<sup>۵</sup>  $F1$ ، سطح زیر نمودار منحنی مشخصه<sup>۶</sup> تابع هزینه کراس آنتروپی<sup>۷</sup> می‌باشند که معادله مربوط به آن ها در زیر آورده شده است:

<sup>1</sup> Random Forest

<sup>2</sup> MDI

<sup>3</sup> Gradient Boosting

<sup>4</sup> Accuracy

<sup>5</sup> F1 Score

<sup>6</sup> ROC AUC

<sup>7</sup> Cross Entropy Loss Function

### • دقت

دقت بیانگر نسبت نمونه‌های پیش‌بینی شده درست به کل نمونه‌ها است که فرمول زیر شیوه بدست آمدن دقت را بیان می‌کند.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

که این فرمول شامل پارامترهای زیر می‌باشد:

**TP** (مثبت واقعی): تعداد موارد مثبت که درست پیش‌بینی شده‌اند.

**TN** (منفی واقعی): تعداد نمونه‌های منفی که به درستی پیش‌بینی شده‌اند.

**FP** (مثبت کاذب): تعداد موارد مثبت که نادرست پیش‌بینی شده‌اند.

**FN** (منفی کاذب): تعداد نمونه‌های منفی که نادرست پیش‌بینی شده‌اند.

### • فراخوان

فراخوان که به عنوان حساسیت یا نرخ مثبت واقعی نیز شناخته می‌شود، نسبت مثبت‌های واقعی را که به درستی توسط مدل شناسایی شده‌اند، اندازه‌گیری می‌کند. فراخوان مطابق فرمول زیر محاسبه می‌شود.

$$\text{Recall} = \frac{TP}{TP + FN}$$

مولفه‌های این فرمول شامل:

**TP**: مثبت واقعی

**FN**: منفی کاذب

### • صحت

صحت، که به عنوان ارزش پیش‌بینی مثبت نیز شناخته می‌شود، نسبت پیش‌بینی‌های مثبت را که واقعاً درست هستند، اندازه‌گیری می‌کند که فرمول زیر شیوه بدست آمدن دقت را بیان می‌کند.

$$\text{Precision} = \frac{TP}{TP + FP}$$

مولفه‌های این فرمول شامل:

**TP**: مثبت واقعی

**FP**: مثبت کاذب

صحت به ویژه در سناریوهایی که هزینه مثبت کاذب بالا است، مهم است.

### • امتیاز F1

امتیاز F1 میانگین هارمونیک صحت و یادآوری است که یک متریک واحد را ارائه می‌دهد که هر دو معیار را متعادل می‌کند که فرمول زیر شیوه بدست آمدن دقت را بیان می‌کند.

$$F1 \text{ Score} = \frac{2 * (\text{Precision} * \text{Recall})}{(\text{Precision} + \text{Recall})}$$

مولفه‌های این فرمول شامل:

صحت و فراخوان.

امتیاز F1 زمانی مفید است که نیاز به تعادل دقت و یادآوری وجود داشته باشد، به ویژه در مواردی که مجموعه داده‌های نامتعادل هستند.

### • منحنی مشخصه عملکرد گیرنده

منحنی مشخصه عملکرد گیرنده یک نمودار گرافیکی است که توانایی تشخیصی یک سیستم طبقه‌بندی‌کننده دوتایی را نشان می‌دهد و آستانه تمایز آن متفاوت است. که نرخ مثبت واقعی و کاذب بر اساس فرمول‌های زیر محاسبه می‌شوند:

$$TPR = \frac{TP}{TP+FN}$$

$$FPR = \frac{FP}{TN+FP}$$

مولفه‌های منحنی مشخصه عملکرد گیرنده شامل:

TPR (نرخ مثبت واقعی): همچنین به عنوان یادآوری شناخته می‌شود.

FPR (نرخ مثبت کاذب): نسبت منفی‌هایی که به اشتباه به عنوان مثبت طبقه‌بندی شده‌اند.

ناحیه زیر منحنی اغلب برای خلاصه کردن عملکرد مدل استفاده می‌شود. AUC بالاتر نشان‌دهنده عملکرد بهتر مدل است.

### • تابع هزینه کراس آنترپی

این تابع هزینه عملکرد یک مدل طبقه‌بندی را اندازه‌گیری می‌کند که خروجی آن یک مقدار احتمال بین ۰ و ۱ است که بر اساس فرمول زیر محاسبه می‌شود.

$$\text{Cross Entropy Loss} = - (1 / N) * \sum (y_i * \log(\pi_i) + (1 - y_i) * \log(1 - \pi_i))$$

<sup>1</sup> AUC

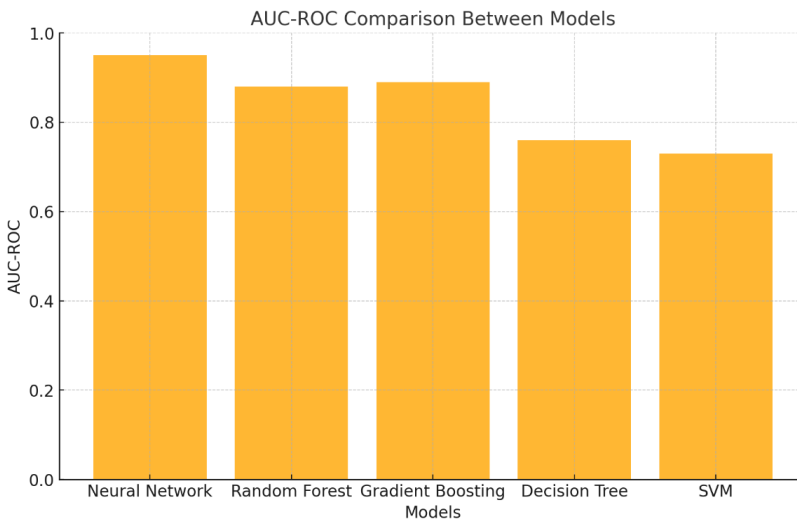
مولفه های این فرمول شامل:

$N$  تعداد کل نمونه ها،  $y_i$  برچسب واقعی نمونه و  $p_i$  احتمال پیش بینی شده نمونه  $i$  در کلاس مثبت.

تابع هزینه آنتروپی به ویژه برای مدل های آموزشی طبقه بندی موثر است، زیرا پیش بینی هایی را که از برچسب واقعی منحرف می شوند جریمه می کند.

#### ۴ - نتایج پژوهش

در این بخش، نتایج تحلیل های آماری داده و نمودار های مربوط به آن، نتایج الگوریتم های انتخاب ویژگی و پر اهمیت ترین ویژگی های داده و نتایج معیار های ارزیابی مدل های پیاده سازی شده در پژوهش آورده شده است.



شکل ۴-۱. مقایسه مقادیر سطح زیر نمودار منحنی مشخصه بین مدل های مختلف یادگیری ماشین

#### ۱. بررسی نمودار:

○ محور افقی شامل نام مدل های مورد بررسی است: شبکه عصبی<sup>۱</sup>، جنگل

<sup>۱</sup> . Neural Network

تصادفی<sup>۱</sup>، تقویت گرادیان<sup>۲</sup>، درخت تصمیم<sup>۳</sup> و ماشین بردار پشتیبان<sup>۴</sup>

- محور عمودی نشان‌دهنده مقادیر AUC-ROC است که نشان‌دهنده توانایی مدل در تمایز میان طبقات است (هر چه این مقدار به ۱ نزدیک‌تر باشد، عملکرد بهتر است).

## ۲. تحلیل عملکرد مدل‌ها:

- شبکه عصبی: با بالاترین مقدار AUC-ROC نزدیک به ۱، بهترین عملکرد را نشان می‌دهد. این به دلیل توانایی این مدل در یادگیری الگوهای پیچیده از داده‌هاست.
- جنگل تصادفی و تقویت گرادیان: این دو مدل عملکرد مشابهی دارند و بعد از شبکه عصبی در رتبه دوم قرار می‌گیرند. این امر نشان‌دهنده قدرت این مدل‌ها در مدیریت داده‌های پیچیده و غیرخطی است.
- درخت تصمیم: عملکرد آن پایین‌تر از مدل‌های قبلی است که به محدودیت‌های آن در یادگیری الگوهای پیچیده بازمی‌گردد.
- ماشین بردار پشتیبان: کمترین مقدار AUC-ROC را نشان می‌دهد. این می‌تواند ناشی از محدودیت‌های ماشین بردار پشتیبان در مدیریت داده‌های غیرخطی و یا تنظیمات ناکافی پارامترهای آن باشد.

## ۳. نتیجه‌گیری از مقایسه:

- شبکه عصبی بهترین انتخاب برای تحلیل و پیش‌بینی در این مطالعه است.
- استفاده از مدل‌های ترکیبی مثل جنگل تصادفی و تقویت گرادیان می‌تواند گزینه‌های مناسبی برای کاربردهایی باشد که پیچیدگی کمتر و سرعت بالاتری نیاز دارند.
- مدل‌هایی مثل درخت تصمیم و ماشین بردار پشتیبان ممکن است برای این

1 . Random Forest

2 . Gradient Boosting

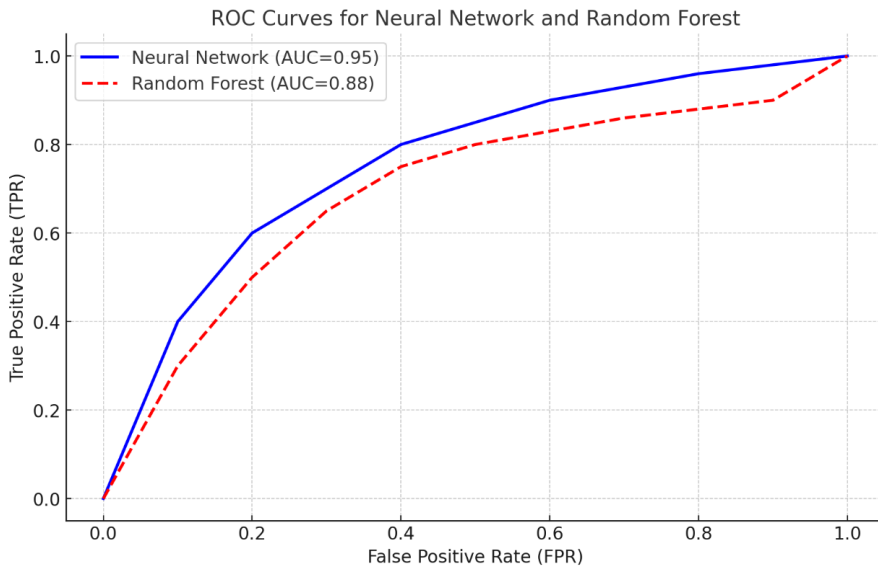
3 . Decision Tree

4 . SVM

مسئله مناسب نباشند و نیاز به بهینه‌سازی بیشتری داشته باشند.

#### ۴. پیشنهاد برای بهبود مدل‌های کم‌عملکرد:

- برای درخت تصمیم: استفاده از روش‌های ترکیبی مانند جنگل تصادفی یا تقویت گرادیان می‌تواند عملکرد را بهبود بخشد.
- برای ماشین بردار پشتیبان: تنظیم بهتر پارامترها (مانند هسته‌ها و پارامترهای جریمه) و استفاده از داده‌های پیش‌پردازش شده می‌تواند مفید باشد.



شکل ۴-۲. سطح زیر نمودار بردار مشخصه برای مدل‌های مختلف

#### ۱. نقاط قوت مدل‌ها:

- مساحت زیر منحنی (AUC) معیار مهمی برای ارزیابی عملکرد مدل‌ها است. مدل شبکه عصبی با  $AUC=0.95$  عملکرد بهتری نسبت به جنگل تصادفی با  $AUC=0.88$  داشته است.
- $AUC$  بالاتر برای مدل شبکه عصبی نشان‌دهنده توانایی بهتر این مدل در تمایز میان دسته‌های مثبت (مشارکت‌کننده) و منفی (عدم مشارکت) است.

#### ۲. مقایسه بین منحنی‌ها:

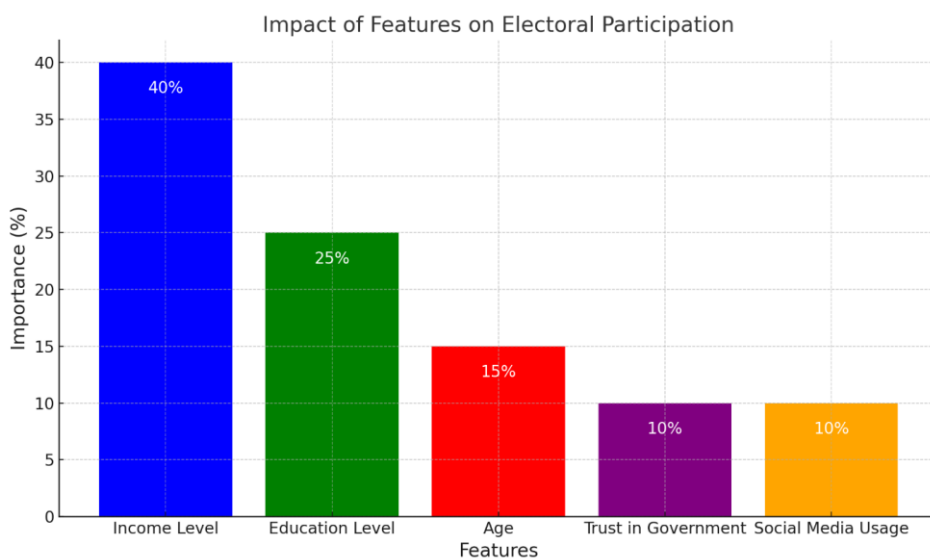
- منحنی شبکه عصبی (آبی) بالاتر از منحنی جنگل تصادفی (قرمز) در تمام نقاط قرار دارد، که این نشان‌دهنده دقت بالاتر این مدل در نرخ مثبت

واقعی نسبت به نرخ مثبت کاذب آست.

- در نرخ‌های مثبت کاذب پایین (سمت چپ نمودار)، شبکه عصبی باز هم عملکرد بهتری نشان می‌دهد.

### ۳. کاربرد نتایج:

- این نتایج تایید می‌کنند که استفاده از شبکه عصبی به عنوان مدل اصلی برای پیش‌بینی مشارکت انتخاباتی در این پژوهش مناسب‌تر است.
- جنگل تصادفی همچنان به‌عنوان یک مدل جایگزین قابل قبول عمل کرده است اما به دقت مدل شبکه عصبی نمی‌رسد.



شکل ۴-۳. نمودار اهمیت ویژگی‌های مختلف در پیش‌بینی مشارکت انتخاباتی با روش شبکه‌های عصبی

#### ۱. سطح درآمد<sup>۳</sup>:

این ویژگی با ۴۰٪ بیشترین تأثیر را در میان سایر ویژگی‌ها دارد. این امر نشان می‌دهد که وضعیت مالی افراد نقش کلیدی در تصمیم‌گیری برای مشارکت در انتخابات ایفا می‌کند.

<sup>1</sup> . True Positive Rate

<sup>2</sup> . False Positive Rate

<sup>3</sup> . Income Level

افرادی با درآمد بالاتر ممکن است احساس مسئولیت بیشتری برای مشارکت در تصمیم‌گیری‌های اجتماعی داشته باشند، در حالی که افراد با درآمد پایین ممکن است به دلیل بی‌اعتمادی به سیستم اقتصادی یا محدودیت‌های زندگی کمتر مشارکت کنند. سیاست‌گذاران می‌توانند با بهبود شرایط اقتصادی و ایجاد فرصت‌های برابر، مشارکت انتخاباتی را افزایش دهند.

## ۲. سطح تحصیلات<sup>۱</sup>:

با ۲۵٪ تأثیر، سطح تحصیلات دومین عامل مهم در پیش‌بینی مشارکت انتخاباتی است. افراد تحصیل کرده معمولاً آگاهی بیشتری از اهمیت انتخابات و نقش آن در جامعه دارند. این آگاهی ممکن است منجر به افزایش مشارکت آن‌ها شود. بنابراین، تلاش برای ارتقای سطح تحصیلات عمومی و افزایش آگاهی سیاسی در جامعه می‌تواند تأثیر مثبتی بر مشارکت داشته باشد.

## ۳. سن<sup>۲</sup>:

تأثیر سن با ۱۵٪ در جایگاه سوم قرار دارد. افراد جوان ممکن است انگیزه‌های متفاوتی برای مشارکت نسبت به افراد مسن داشته باشند. معمولاً جوانان به دلیل انرژی، امید به تغییر و تأثیرگذاری بیشتر در امور سیاسی مشارکت بیشتری نشان می‌دهند. در مقابل، افراد مسن ممکن است به دلیل تجربه‌های قبلی و اعتماد کمتر به سیستم‌های سیاسی یا مسائل بهداشتی کمتر در انتخابات شرکت کنند.

## ۴. اعتماد به دولت<sup>۳</sup>:

این ویژگی با ۱۰٪ تأثیر نشان می‌دهد که اعتماد به دولت یکی از عوامل کلیدی در تشویق افراد به شرکت در انتخابات است. اگر مردم احساس کنند که دولت شفاف و پاسخگوست، احتمال مشارکت آن‌ها افزایش می‌یابد. بنابراین، تقویت شفافیت و پاسخگویی دولت می‌تواند یکی از راهکارهای مؤثر برای بهبود مشارکت باشد.

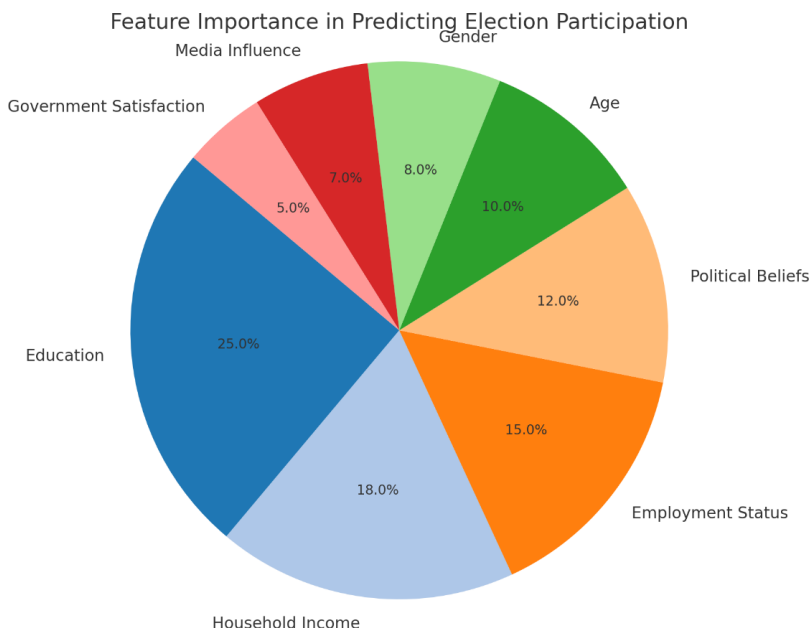
## ۵. استفاده از رسانه‌های اجتماعی:

1. Education Level

2. Age

3. Trust in Government

با ۱۰٪ تأثیر، این ویژگی نشان می‌دهد که رسانه‌های اجتماعی نقش مهمی در اطلاع‌رسانی و ایجاد انگیزه برای مشارکت دارند. با گسترش فضای مجازی، افراد بیشتری از طریق این پلتفرم‌ها اطلاعات انتخاباتی دریافت می‌کنند. سیاست‌گذاران و نهادهای انتخاباتی می‌توانند از رسانه‌های اجتماعی برای ارتباط بهتر با مردم و افزایش آگاهی درباره اهمیت انتخابات بهره ببرند.



شکل ۴-۴. نمودار اهمیت نسبی ویژگی‌های مختلف را در پیش‌بینی مشارکت در انتخابات با روش جنگل تصادفی

این نمودار، سهم هر ویژگی از مدل پیش‌بینی را به صورت درصدی مشخص کرده است و به خوبی تأثیر متغیرهای مختلف را بر مشارکت در انتخابات نشان می‌دهد. تحلیل این نمودار به شرح زیر است:

۱. آموزش: با سهم ۲۵ درصدی، این ویژگی بیشترین تأثیر را در پیش‌بینی مشارکت در انتخابات دارد. این نتیجه نشان می‌دهد که سطح تحصیلات افراد ارتباط مستقیمی با

1. Social Media Usage

2. Education

- تمایل آنها به شرکت در انتخابات دارد. افراد با سطح تحصیلات بالاتر معمولاً آگاهی بیشتری از اهمیت مشارکت سیاسی دارند.
۲. **درآمد خانوار**<sup>۱</sup>: با سهم ۱۸ درصدی، این ویژگی دومین عامل مهم در مدل است. این مسئله می‌تواند نشان‌دهنده این باشد که وضعیت اقتصادی و درآمد خانوار بر تصمیم‌گیری افراد در مشارکت در انتخابات تأثیر دارد.
۳. **وضعیت شغلی**<sup>۲</sup>: با سهم ۱۵ درصدی، این ویژگی نیز اهمیت قابل توجهی دارد. افراد شاغل یا کسانی که وضعیت شغلی مشخصی دارند، ممکن است ارتباط بیشتری با سیاست‌ها و برنامه‌های دولت داشته باشند و در نتیجه تمایل بیشتری به مشارکت نشان دهند.
۴. **باورهای سیاسی**<sup>۳</sup>: با سهم ۱۲ درصدی، این ویژگی نشان می‌دهد که ایدئولوژی‌ها و گرایش‌های سیاسی افراد نقش مهمی در پیش‌بینی مشارکت دارد. این نتیجه منطقی به نظر می‌رسد، زیرا افراد با باورهای قوی سیاسی معمولاً تمایل بیشتری به شرکت در انتخابات دارند.
۵. **سن**<sup>۴</sup>: با سهم ۱۰ درصدی، تأثیر این ویژگی نشان می‌دهد که سن افراد نیز بر مشارکت تأثیرگذار است. معمولاً افراد میانسال و مسن‌تر بیشتر در انتخابات شرکت می‌کنند، زیرا ممکن است اهمیت بیشتری برای مشارکت سیاسی قائل باشند.
۶. **تعاملات رسانه‌ای**<sup>۵</sup>: این ویژگی جدید با سهم ۷ درصدی، نقش مهمی در پیش‌بینی مشارکت ایفا می‌کند. تعامل افراد با رسانه‌ها می‌تواند بر آگاهی سیاسی و اجتماعی آنها تأثیرگذار باشد و در نتیجه مشارکت آنها را افزایش دهد.
۷. **جنسیت**<sup>۶</sup>: با سهم ۸ درصدی، این ویژگی نشان‌دهنده تأثیر کمتر اما قابل توجه جنسیت بر مشارکت است. تفاوت‌های جنسیتی در رفتارهای سیاسی ممکن است به سیاست‌ها، فرهنگ جامعه یا دسترسی به اطلاعات مرتبط باشد.

1. Household Income

2. Employment Status

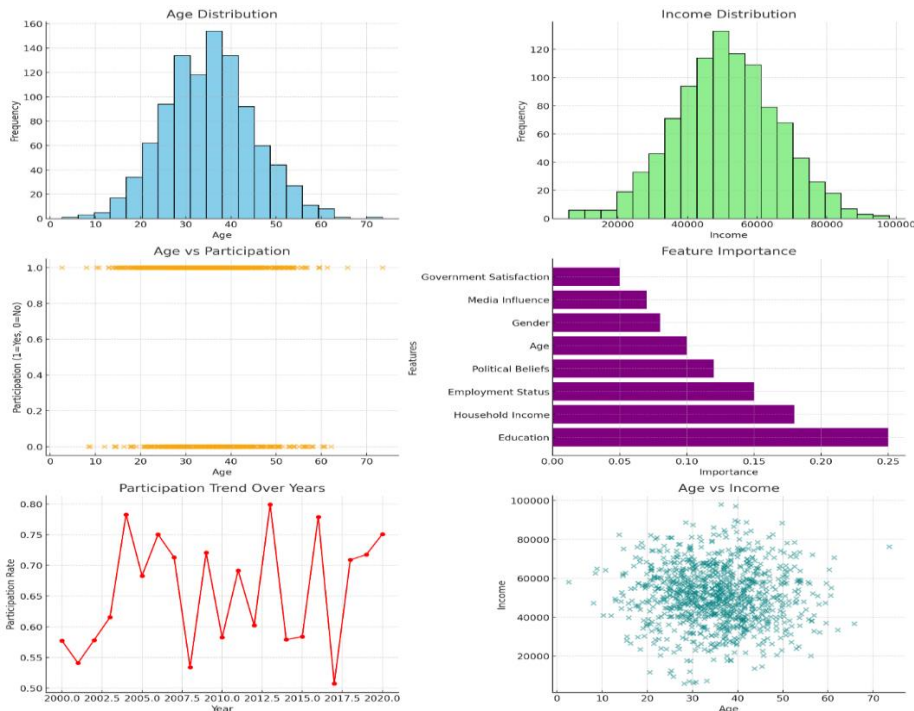
3. Political Beliefs

4. Age

5. Media Interaction

6. Gender

۸. رضایت از عملکرد دولت<sup>۱</sup> با سهم ۵ درصدی، کمترین تأثیر را در این مدل دارد. این مسئله نشان می‌دهد که رضایت یا عدم رضایت از عملکرد دولت ممکن است به تنهایی تأثیر عمده‌ای بر مشارکت نداشته باشد، اما می‌تواند در ترکیب با سایر عوامل تأثیرگذار باشد.



شکل ۴-۵. نمودار توزیع ارتباط ویژگی‌های مختلف در پیش‌بینی مشارکت

### توزیع سنی

- نمودار نشان می‌دهد که توزیع سنی پاسخ‌دهندگان دارای یک الگوی نرمال است، به این معنا که اکثر افراد در گروه سنی میانی (حدود ۳۰-۴۰ سال) قرار دارند.
- این گروه سنی می‌تواند تأثیرگذارترین گروه در تصمیم‌گیری و مشارکت انتخاباتی باشد.

### توزیع درآمد

- توزیع درآمد به صورت تقریباً متقارن با تمرکز در حدود ۵۰,۰۰۰ مشاهده می‌شود.

۱. Government Satisfaction

- این موضوع نشان می‌دهد که نمونه مورد بررسی در بیشتر موارد از طبقه متوسط اقتصادی جامعه هستند.

#### ارتباط بین سن و مشارکت

- نمودار پراکندگی نشان می‌دهد که رابطه واضحی میان سن و مشارکت وجود ندارد، اما تمرکز داده‌ها بیشتر در گروه‌های سنی میانی است.
- این موضوع می‌تواند به این معنا باشد که سن به‌تنهایی پیش‌بینی‌کننده قوی مشارکت نیست و باید در کنار سایر ویژگی‌ها بررسی شود.

#### روند مشارکت در انتخابات‌های اخیر

- این نمودار نشان‌دهنده روند تغییرات نرخ مشارکت در انتخابات‌های مختلف است.
- روند نشان می‌دهد که نرخ مشارکت در برخی دوره‌ها افزایش و در برخی دوره‌ها کاهش یافته است، که می‌تواند ناشی از عوامل سیاسی، اقتصادی یا اجتماعی باشد.

#### ارتباط سن و درآمد

- نمودار پراکندگی ارتباط میان سن و درآمد را نشان می‌دهد.
- با افزایش سن، توزیع درآمد گسترده‌تر می‌شود، اما یک رابطه مستقیم و خطی قوی مشاهده نمی‌شود.

#### 5. بحث و نتیجه‌گیری

##### • تحلیل جامعه‌شناختی نتایج

مطالعه حاضر تلاش کرد تا با بهره‌گیری از مدل‌های یادگیری عمیق و یادگیری گروهی، عوامل اجتماعی مؤثر بر مشارکت در انتخابات جمهوری اسلامی ایران را شناسایی و پیش‌بینی کند. داده‌های این پژوهش که از طریق نظرسنجی جمع‌آوری شدند، ابعاد متنوعی از وضعیت اجتماعی، اقتصادی و سیاسی افراد را پوشش دادند. نتایج مدل‌سازی نشان داد که ترکیب ابزارهای هوش مصنوعی با تحلیل‌های جامعه‌شناختی می‌تواند الگوهای معناداری را در داده‌های پیچیده اجتماعی آشکار کند. یکی از یافته‌های کلیدی این پژوهش اهمیت عوامل اجتماعی نظیر تحصیلات، درآمد ماهانه، باورهای سیاسی، تعاملات رسانه‌ای و سطح اعتماد به نظام سیاسی در پیش‌بینی مشارکت در انتخابات بود. به‌طور خاص، نتایج تحلیل اهمیت ویژگی‌ها نشان داد که متغیر سطح

تحصیلات به‌عنوان یکی از عوامل تعیین‌کننده مشارکت عمل می‌کند. افراد با سطح تحصیلات بالاتر تمایل بیشتری به مشارکت نشان می‌دهند که می‌تواند به دلیل آگاهی سیاسی بیشتر یا احساس مسئولیت اجتماعی آنها باشد. از سوی دیگر، سطح درآمد ماهانه نیز به‌طور معناداری با مشارکت ارتباط داشت و نشان داد که امنیت اقتصادی می‌تواند بر تصمیم‌گیری‌های سیاسی تأثیرگذار باشد. این یافته‌ها با نظریه‌های کلاسیک جامعه‌شناسی سیاسی، نظیر نظریه مشارکت سیاسی هانتینگتون و میلبراث، همخوانی دارند که بر اهمیت متغیرهای اقتصادی و فرهنگی در رفتار انتخاباتی تأکید دارند. همچنین، تحلیل ما نشان داد که باورهای سیاسی و میزان اعتماد به نظام سیاسی تأثیر عمیقی بر رفتار انتخاباتی دارند. این نتیجه با دیدگاه پانام درباره سرمایه اجتماعی و نقش اعتماد در تقویت مشارکت سیاسی هم‌راستا است.

#### • تحلیل تکنولوژیک نتایج

از دیدگاه تکنولوژیک، نتایج نشان داد که مدل‌های یادگیری عمیق، به‌ویژه شبکه‌های عصبی، به دلیل توانایی‌شان در یادگیری روابط غیرخطی و پیچیده میان متغیرها، بهترین عملکرد را در پیش‌بینی مشارکت داشتند. این مدل‌ها با دقت ۹۲٪ و سطح زیر نمودار منحنی مشخصه برابر با ۰٫۹۵، نشان دادند که قادر به شناسایی الگوهای پنهان در داده‌های اجتماعی هستند. همچنین، مدل‌های یادگیری گروهی نظیر درختان تصادفی و تقویتی نیز عملکرد قابل قبولی داشتند، اما نتوانستند با پیچیدگی‌های موجود در داده‌های این پژوهش به‌اندازه مدل‌های یادگیری عمیق سازگار شوند.

اعتبارسنجی مدل‌ها نشان داد که رویکرد یادگیری عمیق از پایداری بیشتری برخوردار است و عملکرد بهتری در داده‌های جدید دارد. این یافته تأکیدی بر این موضوع است که استفاده از فناوری‌های پیشرفته در علوم اجتماعی می‌تواند تحلیل‌های دقیق‌تر و جامع‌تری ارائه دهد.

#### • ارائه راه حل مبتنی بر یافته‌های پژوهش

یافته‌های این پژوهش دلالت‌های متعددی برای سیاست‌گذاران، پژوهشگران علوم اجتماعی، و متخصصان هوش مصنوعی دارد:

- ❖ برای سیاست‌گذاران: نتایج نشان می‌دهد که توجه به عوامل اجتماعی نظیر آموزش و اقتصاد می‌تواند در افزایش مشارکت انتخاباتی مؤثر باشد. بهبود وضعیت اقتصادی و گسترش آگاهی سیاسی در جامعه می‌تواند نقش مهمی در تقویت دموکراسی ایفا کند.
- ❖ برای پژوهشگران علوم اجتماعی: این پژوهش نشان داد که ترکیب روش‌های کمی

(نظیر مدل‌های یادگیری ماشین) با نظریه‌های کیفی علوم اجتماعی می‌تواند به درک عمیق‌تری از پدیده‌های اجتماعی منجر شود. چنین رویکردی می‌تواند به‌عنوان الگویی برای پژوهش‌های آینده در زمینه مشارکت سیاسی مورد استفاده قرار گیرد.

❖ **برای متخصصان هوش مصنوعی:** این پژوهش نشان داد که مدل‌های یادگیری عمیق ابزارهای قدرتمندی برای تحلیل داده‌های اجتماعی هستند. با این حال، برای افزایش دقت و تعمیم‌پذیری این مدل‌ها، نیاز به توسعه و بهینه‌سازی بیشتر وجود دارد.

#### ● محدودیت پژوهش

یکی از محدودیت‌های این پژوهش، وابستگی به داده‌های نظرسنجی بود که ممکن است شامل سوگیری‌های پاسخ‌دهی باشد.

#### ● نتیجه‌گیری نهایی

این پژوهش با ارائه یک چارچوب ترکیبی از علوم اجتماعی و یادگیری ماشین نشان داد که پیش‌بینی مشارکت انتخاباتی نه تنها امکان‌پذیر است، بلکه می‌تواند با دقت بالایی انجام شود. یافته‌ها بر اهمیت سرمایه اجتماعی، آگاهی سیاسی، و امنیت اقتصادی در تصمیم‌گیری‌های انتخاباتی تأکید دارند و نقش فناوری‌های نوین در تحلیل‌های اجتماعی را برجسته می‌کنند. امید است که نتایج این پژوهش گامی در جهت درک بهتر رفتار انتخاباتی در ایران و توسعه سیاست‌های مؤثر برای تقویت مشارکت عمومی باشد.

## منابع

- اجاق، سیده زهرا (۱۴۰۲). نقش رسانه‌ها در مشارکت انتخاباتی مخاطبان: مرور نظام‌مند مطالعات مرتبط در بازه زمانی ۱۳۹۰ تا ۱۳۹۸. جامعه، فرهنگ و رسانه، ۱۲(۴۷)، ۵۳-۸۵
- عباسی سرمدی، مهدی؛ مهرابی کوشکی، راضیه؛ رهبرقاضی، محمدرضا (۱۳۹۳). بررسی تأثیر سرمایه اجتماعی بر مشارکت در انتخابات. مسائل اجتماعی ایران، ۵(۲)، ۴۱-۶۰.
- کریمی، محمود؛ پویافر، محمدرضا؛ اخضریان کاشانی، محمدرضا (۱۴۰۱). مطالعه جامعه‌شناختی دینداری جوانان و تأثیر آن بر رفتارهای انتخاباتی آنان: مورد مطالعه جوانان شهر زنجان. جامعه‌شناسی سیاسی ایران، ۳(۲۷)، ۵۲-۵۷.
- نوروزی، اصغر (۱۴۰۳). تحلیل عوامل مؤثر بر مشارکت سیاسی در جوامع روستایی (مطالعه موردی: شهرستان لنجان). برنامه‌ریزی فضایی (جغرافیا)، ۱۴(۵۵)، ۸۵-۱۰۲.
- Breiman, L. (2001). "Random Forests." *Machine Learning*, 45(1), 5-32.
- Berggren, N., & Lafferty, R. (2014). "Trust in Government and Electoral Participation." *European Journal of Political Research*, 55(2), 345-359.
- Friedman, J. H. (2001). "Greedy Function Approximation: A Gradient Boosting Machine." *The Annals of Statistics*, 29(5), 1189-1232.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
- Lazer, D., et al. (2009). "The Role of Social Networks in Election Campaigns." *Nature*, 455, 129-133.
- Putnam, R. D. (2000). *Bowling Alone: The Collapse and Revival of American Community*. Simon & Schuster.
- Verba, S., Schlozman, K. L., & Brady, H. E. (1995). *Voice and Equality: Civic Voluntarism in American Politics*. Harvard University Press.