

## تأثیر مداخله ارسال پیام‌های اصلاحی بر درگیری کاربران منتشرکننده اخبار جعلی در ایکس (تویتر)

### The Effect of Correction Intervention on Engagement of Users Sharing Fake News on X (Twitter)

**Mohammad Hasan Ebrahim Kani**

M. A. in General Psychology, Faculty of Psychology and Educational Sciences, University of Tehran, Tehran, Iran.

**Dr. Reza Pourhosein\***

Associate Professor, Department of Cognitive Science, Faculty of Psychology and Educational Sciences, University of Tehran, Tehran, Iran.

[prhosein@ut.ac.ir](mailto:prhosein@ut.ac.ir)

**Dr. Siyavash Salavatian**

Associate Professor, Department of Media Management, Faculty of Communication & Media, IRIB University, Tehran, Iran.

محمدحسن ابراهیم کنی

کارشناسی ارشد روان‌شناسی عمومی، دانشکده روان‌شناسی و علوم تربیتی، دانشگاه تهران، تهران، ایران.

دکتر رضا پورحسین (نویسنده مسئول)

دانشیار، گروه روان‌شناسی، دانشکده روان‌شناسی و علوم تربیتی، دانشگاه تهران، تهران، ایران.

دکتر سیاوش صلواتیان

دانشیار، گروه مدیریت رسانه، دانشکده ارتباطات و رسانه، دانشگاه صدا و سیما، تهران، ایران.

## Abstract

This study aimed to compare the causal effect of one of the interventions to fight fake news (sending correction messages) on Persian-speaking users who spread false news by investigating the level of their engagement with this message. The study method was experimental and based on a randomized field experiment. The population was targeted by X Persian-speaking users who published specific fake news. The study sample was 334 of these users who were randomly selected within the first 48 hours of the news release and randomly assigned to 3 experimental groups. The data of the study was extracted through the application program interface (API) of X and subjected to the analysis of binominal logistic regression and chi-square test. The implementation of the intervention was that after the preparation of a neutral account by the researcher, three types of corrective messages were sent to these users and their engagement with the corrective message was studied within 24 hours. The results showed that the message that contained only the truth was significantly more effective than the message that contained the truth vs. rumors ( $p < 0.05$ ). Also, the characteristics of the users did not affect their engagement with the corrective message. According to the existing research gap on the efficiency of different approaches, this study showed for the first time in the world that the approach of simply stating the truth is more effective. The results of this intervention can be applied in social media to fight fake news.

**Keywords:** Correction, Fake news, Randomized Field Experiment, Social Media, Twitter.

## چکیده

هدف از مطالعه حاضر مقایسه تأثیر علی یکی از مداخله‌های مقابله با اخبار جعلی یعنی ارسال پیام‌های اصلاحی، بر روی کاربران فارسی‌زبان منتشرکننده اخبار نادرست از طریق بررسی میزان درگیری آنها با این پیام بود. روش مطالعه از نوع آزمایشی و بر اساس طرح آزمایش میدانی تصادفی اجرا شد. جامعه مورد هدف کاربران فارسی‌زبان ایکس قرار داده شد که اقدام به انتشار یک خبر جعلی مشخص کرده بودند. نمونه مورد مطالعه ۳۳۴ نفر از این کاربران بودند که در فاصله ۴۸ ساعت ابتدایی انتشار خبر، به صورت کاملاً تصادفی انتخاب و به صورت تصادفی به ۳ گروه آزمایشی تخصیص داده شدند. داده‌های مطالعه از طریق رابط برنامه کاربردی (API) ایکس استخراج و مورد تحلیل رگرسیون لجستیک اسمی دو وجهی و آزمون استقلال خی دو قرار گرفت. اجرای مداخله به این صورت بود که بعد از آماده‌سازی یک حساب کاربری خنثی توسط محقق، سه نوع پیام اصلاحی برای این کاربران ارسال شده و در فاصله ۲۴ ساعت درگیری آنها با پیام اصلاحی مورد مطالعه قرار می‌گرفت. نتایج نشان داد پیامی که صرفاً حاوی حقیقت بود نسبت به پیامی که حاوی حقیقت و شایعه بود به صورت معنی‌داری تأثیر بیشتری داشت ( $p < 0.05$ ). همچنین ویژگی‌های کاربران تأثیری بر درگیری آنها با پیام اصلاحی نداشت. باتوجه به خلاء پژوهشی موجود در موضوع کارآمدی رویکردهای مختلف اصلاح، این مطالعه برای اولین بار در دنیا نشان داد در متغیر درگیری، رویکرد صرفاً بیان حقیقت کارآمدی بیشتری دارد. نتایج این مداخله قابلیت کاربردی‌سازی در رسانه‌های اجتماعی برای مقابله با اخبار جعلی را دارد.

**واژه‌های کلیدی:** اصلاح، اخبار جعلی، آزمایش میدانی تصادفی، رسانه‌های

اجتماعی، تویتر.

اخبار جعلی<sup>۱</sup>، محتوای خبری هستند که در بستر اینترنت منتشر شده و علی‌رغم اینکه شبیه به محتوای خبری اصلی و قانونی بنظر می‌رسند، ساختگی یا بسیار نادرست به حساب می‌آیند (پنیکوک و رند<sup>۲</sup>، ۲۰۲۱a). انتشار اخبار جعلی و نادرست در سال‌های اخیر و با گسترش شبکه‌های اجتماعی نگرانی‌های بسیاری ایجاد کرده است (وئوکی و همکاران<sup>۳</sup>، ۲۰۱۸). این نگرانی‌ها در وقایعی چون انتخابات‌های ۲۰۱۶ (لازر و همکاران<sup>۴</sup>، ۲۰۱۸) و ۲۰۲۰ آمریکا (پنیکوک و رند، ۲۰۲۱b)، خروج کشور انگلستان از اتحادیه اروپا (لازر و همکاران، ۲۰۱۸) و همه‌گیری بیماری کووید-۱۹ (لومبا و همکاران<sup>۵</sup>، ۲۰۲۱) باعث توجه بیش از پیش دانشگاهیان، سیاست‌گذاران و اهالی رسانه به این موضوع شد. این اخبار تهدیدی جدی برای افراد و جوامع به حساب می‌آید (لواندوفسکی و همکاران<sup>۶</sup>، ۲۰۱۷) و می‌تواند صدمات جبران‌ناپذیری در موضوعات مختلفی چون سلامت عمومی در زمان شیوع همه‌گیری‌ها، دوقطبی‌شدن جامعه و کاهش اعتماد به دولت‌ها وارد کنند (جانسون و همکاران<sup>۷</sup>، ۲۰۲۰؛ جولی و پترسون<sup>۸</sup>، ۲۰۲۰؛ واسودوا و بارکدول<sup>۹</sup>، ۲۰۲۰؛ فریمن و همکاران<sup>۱۰</sup>، ۲۰۲۰).

شبکه‌های اجتماعی امروزه در حال تبدیل‌شدن به محل اصلی دریافت، مصرف و انتشار اطلاعات و اخبار می‌باشند (پرین<sup>۱۱</sup>، ۲۰۱۵) و این موضوع امروزه نگرانی‌های زیادی ایجاد کرده است (استوارت و همکاران<sup>۱۲</sup>، ۲۰۱۹). در میان رویکردها و رشته‌های مختلف فعال در موضوع اخبار جعلی این روان‌شناسی، علوم شناختی و علوم رفتاری است که در سال‌های اخیر توانسته ذیل حوزه روان‌شناسی اخبار جعلی، درکی واقع‌بینانه‌تر و عمیق‌تر از این چالش جهانی ارائه دهد (پنیکوک و رند، ۲۰۲۱a؛ اکر و همکاران<sup>۱۳</sup>، ۲۰۲۲). این مطالعات در سال‌های اخیر، علاوه بر توفیقات نظری و دانشگاهی، مورد توجه دولت‌ها و سازمان‌های مختلف در جهان نیز قرار گرفته‌اند و به‌صورت عملیاتی از آنها استفاده می‌شود (پولیتیکو<sup>۱۴</sup>، ۲۰۲۲؛ مرکز عالی ارتباطات استراتژیک ناتو<sup>۱۵</sup>، ۲۰۲۱ و وبلاگ توییتر، ۲۰۲۲).

امروزه رویکردهای مختلفی برای مقابله با این دسته از اخبار طراحی و پیاده‌سازی شده‌اند. در یک نگاه و بصورت عمومی می‌توان این رویکردها را به دو دسته مداخلات پیشینی (اعتبارزدایی پیشینی<sup>۱۶</sup>) و مداخلات واکنشی (اعتبارزدایی<sup>۱۷</sup>) تقسیم‌بندی کرد (لواندوفسکی و همکاران، ۲۰۲۰). مداخلات اعتبارزدایی پیشینی به افراد کمک می‌کنند تا بتوانند اخبار نادرست و گمراه‌کننده را تشخیص دهند و سپس در برابر تأثیر آنها مقاومت کنند؛ حتی در برابر اخبار جدیدی که در آینده منتشر می‌شوند (وندر لینگن<sup>۱۸</sup>، ۲۰۲۲). مداخلات اعتبارزدایی نیز مشتمل بر پاسخ به یک خبر نادرست مشخص هستند و نشان می‌دهند چرا آن خبر غلط است (اکر و همکاران، ۲۰۲۲). در زمان‌هایی که امکان جلوگیری از تأثیرگذاری اخبار غلط وجود ندارد، می‌بایست از مداخلات واکنشی کمک گرفت. مطالعات زیادی کارآمدی اعتبارزدایی و اصلاح<sup>۱۹</sup> مستقیم را نشان داده‌اند (چان و همکاران<sup>۲۰</sup>، ۲۰۱۷؛ والتر و مورفی<sup>۲۱</sup>، ۲۰۱۸). مهمترین موضوع در اعتبارزدایی و اصلاح، انجام درست و مؤثر آن است، چرا که در غیر اینصورت می‌تواند اثر عکس بگذارد. یافته‌های امروزی اختلاف نظرهایی بر روی ویژگی‌های اصلاح کارآمد دارند؛ عده‌ای معتقد به رویکرد «صرفاً بیان حقیقت» هستند و بهترین و تنها راه درست مقابله با اخبار غلط را نادیده‌گرفتن اطلاعات نادرست و صرفاً بیان حقیقت می‌دانند (شوارز و همکاران<sup>۲۲</sup>، ۲۰۱۶). این افراد معتقدند اعتبارزدایی اطلاعات غلط عموماً محکوم به شکست است چرا که به آن فضای تنفس بیشتری داده، آشنایی با آن را افزایش می‌دهد و آن را بیشتر باورپذیر می‌کند

1 fake news

2 Pennycook &amp; Rand

3 Vosoughi et al.

4 Lazer et al.

5 Lommba et al.

6 Lewandowsky t al.

7 Johnson et al.

8 Jolley &amp; Paterson

9 Vasudeva &amp; Barkdull

10 Freeman et al.

11 Perrin

12 Stewart et al.

13 Ecker et al.

14 politico

15 north atlantic treaty organization

16 prebunk

17 debunk

18 Van der Linden

19 correction

20 Chan et al.

21 Walter &amp; Murphy

22 Schwarz et al.

(لواندوفسکی و همکاران، ۲۰۱۲). مخالفت اصلی این نگاه با رویکرد «حقیقت در برابر شایعه»<sup>۱</sup> است که یکی از رویکردهای اصلی و پرستفاده در اعتبارزدایی اخبار جعلی به حساب می‌آید و توسط لواندوفسکی و همکاران (۲۰۲۰) شرح داده شده است. این رویکرد معتقد است یک اصلاح ساده نمی‌تواند باعث کنده‌شدن خبر جعلی از ذهن شود و اعتبارزدایی در صورتی موفق است که دارای چهار جزء مشخص باشد: شروع با بیان حقیقت، یکبار اشاره به شایعه، توضیح غلط‌بودن شایعه و نهایتاً تکرار حقیقت. در کنار این دو رویکرد، برخی دیگر معتقدند یکی از مهمترین ویژگی‌های اعتبارزدایی، ارائه توضیحی از حقیقت است که در حالت ایده‌آل باید بیانگر توضیح و روایت جایگزین باشد از اینکه چرا یک چیز رخ داده است (اکر و همکاران، ۲۰۱۰). متقابلاً برخی نیز معتقدند رد ساده خبر جعلی کارآمدتر است و از رویکرد «صرفاً رد شایعه» سخن می‌گویند (لواندوفسکی و همکاران، ۲۰۱۲).

همانگونه که گفته شد مطالعات زیادی تا به امروز بر روی کارآمدی اصلاح و اعتبارزدایی انجام شده است، با این حال، لازمه یک اصلاح کارآمد، ایجاد درگیری<sup>۲</sup> در فرد منتشرکننده خبر جعلی (به عنوان مخاطب یک اصلاح) است چرا که یکی از چالش‌های اعتبارزدایی، نادیده‌گرفتن پیام‌های اصلاحی توسط کاربران منتشرکننده اخبار غلط است؛ به عنوان مثال مارگولین و همکاران<sup>۳</sup> (۲۰۱۸) در مطالعه‌ای نشان دادند ۷۴ درصد اصلاح‌های اجتماعی در توییتر نادیده<sup>۴</sup> گرفته می‌شوند. از این رو یافتن راهکارهایی برای افزایش درگیری با این پیام‌ها، مقدم بر طراحی متون تأثیرگذار بوده و لازمه مقابله مؤثر با این اخبار در شبکه‌های اجتماعی است. به‌صورت ویژه‌تر در سال‌های اخیر، پژوهش‌های زیادی در پی یافتن راه‌هایی برای مقابله با انتشار اخبار گمراه‌کننده و غلط در سکوه‌های شبکه‌های اجتماعی بودند (کوزیروا و همکاران<sup>۵</sup>، ۲۰۲۰؛ ویتنبرگ و همکاران<sup>۶</sup>، ۲۰۲۰). مانند آنچه مارتل و همکاران<sup>۷</sup> اشاره کرده‌اند (۲۰۲۱) این مداخلات در سطح سکو<sup>۸</sup> و سطح کاربر<sup>۹</sup> قابل انجام هستند. یکی از انواع مداخلات برای مقابله با انتشار اخبار جعلی در شبکه‌های اجتماعی، اصلاح اجتماعی<sup>۱۰</sup> است (مارتل و همکاران، ۲۰۲۱) که در آن کاربران این شبکه‌ها، از طریق ارسال پاسخ (ریپلای) به پیام حاوی اطلاعات غلط، یکدیگر را اصلاح می‌کنند. مزیت این روش فراتر از مزایای عمومی اعتبارزدایی و اصلاح این است که می‌تواند علاوه بر فرد دریافت‌کننده آن، بر روی سایر مشاهده‌کنندگان اصلاح نیز اثر داشته باشد و باور آنها را نیز اصلاح کند (بود و وراگا<sup>۱۱</sup>، ۲۰۱۸) که به این اثر اصلاح مشاهده‌ای می‌گویند (وراگا و بود، ۲۰۱۷).

عمده مطالعات انجام‌شده در موضوع اعتبارزدایی و اصلاح، با استفاده از روش‌های پرسشنامه‌ای و شبیه‌سازی صورت گرفته‌اند و از این حیث محدودیت‌های جدی دارند و کارآمدی آنها در دنیای واقعی، نیازمند آزمایش‌های میدانی است (مصلح و همکاران<sup>۱۲</sup>، ۲۰۲۲). سکوه‌های شبکه‌های اجتماعی امروزه فرصت بی‌نظیری برای اجرای آزمایش‌های میدانی فراهم کرده‌اند؛ کاربران این شبکه‌ها را می‌توان بصورت تصادفی به گروه‌های مختلف آزمایش و کنترل تقسیم کرد و تأثیر مداخله را با تحلیل ردپای دیجیتال<sup>۱۳</sup> آنها بر روی رفتارهای شبکه‌های اجتماعی مورد نظارت قرار داده و روابط علی را استخراج کرد (مصلح و همکاران، ۲۰۲۲). این مطالعه اولین مداخله میدانی در موضوع اخبار جعلی بر روی کاربران فارسی‌زبان شبکه‌های اجتماعی محسوب می‌شود و از این حیث می‌تواند برای اولین بار یافته‌هایی جدید از رفتار دیجیتال جامعه ایران بدست دهد. تکیه بر یافتن روابط علی، در مقایسه با مطالعات توصیفی، بیانگر اهمیت دیگر این طرح است. باتوجه به عدم دسترسی کشور به مدیریت سکوه‌های پرتعداد شبکه‌های اجتماعی و اجرای مداخله حاضر در سطح کاربر، این طرح می‌تواند چشم‌انداز جدیدی از مقابله مبتنی بر شواهد علمی با انتشار اخبار جعلی در این شبکه‌ها ارائه دهد.

بنابر موارد ذکرشده در بالا، مطالعه حاضر در پی یافتن راهی مؤثر برای مقابله با انتشار اخبار جعلی در میان کاربران فارسی‌زبان شبکه‌های اجتماعی بود. برای این هدف یک آزمایش میدانی تصادفی در سکوی ایکس (یا همان توییتر) انجام و در آن با ایجاد حساب کاربری محقق‌ساخته، حالت‌های مختلف پیام‌های اصلاحی به نمونه‌ای تصادفی از کاربرانی که یک خبر سیاسی نادرست منتشر کرده‌بودند از طریق پاسخ مستقیم (ریپلای) به توییت حاوی خبر جعلی آنها ارسال شد. باتوجه به خلاء پژوهشی موجود، پیام‌های اصلاحی در سه

1 myth-versus-fact

2 engagement

3 Margolin et al.

4 ignore

5 Kozyreva

6 Wittenberg et al.

7 Martel et al.

8 platform-level

9 user-level

10 social correction

11 Bode & Vraga

12 Mosleh

13 digital trace

حالت مختلف (۱) صرفاً بیان حقیقت، (۲) بیان توأمان حقیقت و شایعه و (۳) صرفاً رد شایعه طراحی و ارسال شدند. تأثیر علی هر یک از انواع اصلاح‌ها، بر روی رفتار درگیری این کاربران با پیام مذکور (پسند پیام اصلاحی، پاسخ به آن، بازنشر آن، حذف توییت اولیه و در مقابل نادیده گرفتن آن) به مدت ۲۴ ساعت مورد مطالعه قرار گرفت. این مطالعه تلاش می‌کند برای اولین بار به این خلاء پژوهشی پرداخته و تأثیر علی هر کدام از این رویکردها در شرایط واقعی و میدانی را مورد بررسی قرار دهد. در واقع هدف این مطالعه، مقایسه تأثیر علی انواع پیام‌های اصلاحی بر درگیری کاربران فارسی‌زبان منتشرکننده اخبار غلط در سکوی ایکس با این پیام است تا موثرترین نوع پیام اصلاحی بین رویکردهای مذکور مشخص شود. سوال پژوهش حاضر این است که کدام نوع از پیام‌های اصلاحی تأثیر بیشتری در درگیری این کاربران دارد و ویژگی کاربران چه نقشی در این بین ایفا می‌کند.

## روش

پژوهش حاضر از نوع مطالعات آزمایشی و طرح آن آزمایش میدانی تصادفی بود. شرکت‌کنندگان طرح به‌دنبال فعالیت روزمره خود در سکوی اجتماعی ایکس مورد مطالعه قرار گرفتند. جامعه مورد هدف طرح، کاربران فارسی‌زبان ایکس بودند که به‌دنبال اتفاقات رخ داده بعد از فوت آقای جواد روحی در تاریخ ۹ شهریور ۱۴۰۲ اقدام به انتشار خبر جعلی در ارتباط با آن کردند. نمونه مورد مطالعه نیز ۳۶۰ نفر از این کاربران بود که با روش نمونه‌گیری تصادفی انتخاب شدند.

برای اجرای مطالعه حاضر چهار فاز طراحی و اجرا شد: در فاز اول، با توجه به فضای ایکس، پیش از هرچیز یک حساب کاربری قدیمی ساخت سال ۲۰۲۰ تهیه و تمام سابقه آن اعم از اطلاعات حساب کاربری و فعالیت رسانه اجتماعی آن حذف و سپس حساب موجود تبدیل به یک حساب خنثی و بدون جهت‌گیری سیاسی و اجتماعی خاص شد. بعد از توافق با شرکت دیتاک برای پشتیبانی از بخش داده‌کاوی طرح، مقدمات لازم برای اجرای مداخله فراهم شد و فضای ایکس فارسی تا زمان انتشار گسترده یک خبر جعلی مورد رصد قرار گرفت.



شکل ۱. حساب کاربری محقق ساخته با شناسه Reza\_Aqaaii

در فاز دوم، سکوی ایکس بصورت روزانه برای یافتن یک خبر جعلی با میزان انتشار بالا مورد رصد قرار گرفت. اولین خبر جعلی منتشرشده در این زمان که به میزان بسیار زیادی در همان ساعات اول انتشار پیدا کرد خبر فوت یک زندانی به نام جواد روحی در زندان نوشهر بود. طبق یافته‌های سامانه دیتاک تنها در ۲۴ ساعت اول، چیزی در حدود ۱۰ هزار توییت با استفاده از کلمات مربوط به نام زندانی زده شد. همزمان سایت‌های مختلف به راستی‌آزمایی این خبر پرداختند و رسانه قوه قضائیه نیز حقیقت ماجرا را بیان کرد (به عنوان نمونه خبرگزاری میزان، ۱۴۰۲ و خبرگزاری ایرنا، ۱۴۰۲). بعد از انتخاب خبر جعلی، با استفاده از سامانه دیتاک و جستجوی کلمات مرتبط، تمام توییت‌های مربوط به این خبر در فاصله حدوداً ۴۸ ساعت بعد از انتشار خبر اول به همراه اطلاعات عمومی حساب‌های کاربری استخراج شد. تعداد این توییت‌ها ۶۰۵۰ عدد بود. در شکل ۲ کلمات استفاده‌شده برای جستجو آمده است.

ساخت کوثری

با استفاده از عملگرهای \* (AND)، + (OR) و ! (NOT) کوثری مناسب موضوع خود را بسازید.

( ) ! + \* )


(کشتن+کشتند+کشتید+کشتین+کشتیش+بکشتن+بکشد+بکشند+می‌کشد+می‌کشند+می‌کشد+می‌کشند+کشته+کشته‌ها+چنایب+قتل+مرگه+رقصیدن+رقص+مسموم+سم+شکنجه+کشته  
{(جواد روحی+جوادروحی+جوادروحي)}(من و تو+منوتو)

تعداد عملگرها : ۲۲/۱۰۰

شکل ۲. کوثری استفاده‌شده برای استخراج توییت‌های مربوط به خبر جواد روحی

تمام این توییت‌ها مشمول انتشار شایعات مربوط به فوت آقای جواد روحی نبودند و تعداد زیادی از آنها با استفاده از کلیدواژه‌های مربوطه به موضوع دیگری پرداخته‌بودند و یا اقدام به اعتبارزدایی این خبر کرده‌بودند. همچنین تعدادی از کاربران بیش از یک توییت زده‌بودند.

در فاز سوم، توییت‌ها بصورت دستی مورد بررسی قرار گرفتند تا تنها مواردی که شامل انتشار خبر جعلی مربوطه بودند، مدنظر قرار بگیرند. جامعه هدف پژوهش تمام ۶۰۵۰ توییت موجود نبود و بخشی از آنها مشمول اهداف این طرح می‌شدند. باتوجه به حجم بالای داده موجود، در ابتدا بصورت تصادفی حجم کوچکی از توییت‌های موجود استخراج شد و سپس تک‌به‌تک مورد بررسی قرار گرفتند و تمام موارد نامربوط حذف شدند. از میان کاربران تکراری نیز تنها توییت آخرشان که بیانگر موضع آخر آنها نسبت به خبر جعلی بود، نگه داشته‌شد. در نتیجه ۱۰۲۳ کاربر یگانه که خبر جعلی منتشر کرده‌بودند، باقی ماندند و از این بین به‌صورت کاملاً تصادفی ۳۶۰ نفر انتخاب و به عنوان شرکت‌کنندگان طرح وارد اجرای طرح شدند. باتوجه به طرح آزمایش، نمونه به سه بازوی آزمایشی تخصیص تصادفی داده شد. سپس بر روی این شرکت‌کنندگان طرح، مداخله اصلاح اجتماعی در فاصله زمانی حدوداً ۷ ساعته (به علت محدودیت‌های ایکس، در ۶ نوبت زمانی) اجرا شد. در نتیجه بجز ۲۶ نفر از کاربران که به دلایل مختلف چون حذف توییت اولیه و حذف حساب کاربری امکان ارسال پیام به آنها وجود نداشت، بر روی باقی ۳۳۴ نفر شرکت‌کننده طرح، مداخله اصلاح اجتماعی به‌صورت موفق اجرا شد.



شکل ۳. طرح آزمایش

در فاز چهارم و آخر نیز نتایج اجرای مداخله به‌مدت ۲۴ ساعت مورد مطالعه قرار گرفت. بدین صورت که درگیری کاربرانی که مورد اصلاح قرار گرفته‌بودند با پیام اصلاحی بررسی شد. منظور از درگیری در اینجا پسند، پاسخ و بازنشر پیام اصلاحی و همچنین حذف توییت اولیه است و در مقابل این موارد نادیده‌گرفتن پیام تعریف شده‌بود. باتوجه به عدم وجود گروه کنترل در طرح آزمایش، تأثیر بازوها به‌صورت مقایسه‌ای با یکدیگر ارزیابی می‌شد. داده‌های این پژوهش با استفاده از نرم‌افزار SPSS-22 مورد تحلیل قرار گرفت. برای این کار از شاخص‌های آمار توصیفی و رگرسیون لجستیک اسمی دو وجهی (BLR) و آزمون استقلال خی دو استفاده شد.

### ابزار سنجش

داده‌های مورد نیاز این پژوهش، ردپای دیجیتال کاربران و شامل اطلاعاتی چون متن توییت‌های منتشرشده، پسندها، بازنشرها، اطلاعات حساب کاربری و غیره بود که از طریق رابط برنامه کاربردی (API)<sup>۱</sup> و همچنین دسترسی پژوهشگر به عنوان یک کاربر این سکو

1 application programming interface (API)

گردآوری شدند. تمام اطلاعات مورد نیاز برای تحلیل نتایج در خود سکو در دسترس قرار داشتند و از طریق فایل اکسل خروجی داده‌کاوی سامانه دیتاک با مشاهده فعالیت‌های کاربران توسط پژوهشگر در مدت انجام آزمایش به‌دست آمدند.

## یافته‌ها

در این مطالعه در مجموع بر روی ۳۳۴ کاربر مداخله انجام شد. توضیحات مربوط به تعداد شرکت‌کننده‌های هر بازوی پژوهشی و فراوانی و درصد درگیری در جدول ۱ آمده است.

جدول ۱. تعداد شرکت‌کنندگان به همراه فراوانی و درصد درگیری

| بازو    | فراوانی درگیری | درصد درگیری | فراوانی نادیده‌گرفتن | درصد نادیده‌گرفتن | مجموع |
|---------|----------------|-------------|----------------------|-------------------|-------|
| بازوی ۱ | ۲۳             | ۲۰.۷۲       | ۸۸                   | ۷۹.۲۸             | ۱۱۱   |
| بازوی ۲ | ۱۱             | ۹.۸۲        | ۱۰۱                  | ۹۰.۱۸             | ۱۱۲   |
| بازوی ۳ | ۲۰             | ۱۸.۰۲       | ۹۱                   | ۸۱.۹۸             | ۱۱۱   |
| مجموع   | ۵۴             | ۱۶.۱۷       | ۲۸۰                  | ۸۳.۸۳             | ۳۳۴   |

از میان ۵۴ مورد درگیری، ۳ مورد مربوط به پسند پیام اصلاحی و ۵۱ مورد باقی‌مانده مربوط به پاسخ به پیام اصلاحی بود. در این مداخله هیچ موردی درگیری از نوع بازنشر پیام اصلاحی و حذف توییت اولیه دیده نشد. باتوجه به ویژگی‌های سکوی ایکس، اطلاعاتی عمومی از حساب کاربری افراد وجود داشت که مواردی از آن نیز مورد تحلیل قرار گرفت. این اطلاعات در جدول ۲ نشان داده شده‌است.

جدول ۲. ویژگی‌های کاربران به همراه میانگین و انحراف استاندارد

| متغیر                                        | میانگین  | انحراف استاندارد | بالا ترین | پایین ترین |
|----------------------------------------------|----------|------------------|-----------|------------|
| تعداد پسند توییت خبر جعلی                    | ۷۷.۹۰    | ۵۳۰.۳۰           | ۷۵۰۵      | ۰          |
| تعداد دنبال‌کننده                            | ۱۹۴۵۲.۵۷ | ۱۷۵۹۶۷.۴۱        | ۲۲۶۸۱۸۹   | ۰          |
| تعداد دنبال‌شونده                            | ۹۱۰.۲۴   | ۱۲۱۶.۲۶          | ۷۲۶۷      | ۰          |
| تعداد کل پسند                                | ۳۹۵۸۲.۲۷ | ۷۳۳۹۰.۰۵         | ۶۴۱۲۷۵    | ۰          |
| تعداد کل توییت                               | ۲۲۰۴۱.۲۵ | ۴۵۴۷۹.۰۲         | ۳۹۷۳۳۶    | ۳          |
| عمر حساب کاربری                              | ۱۹۳۱.۹۴  | ۳۵۲۹.۱۷          | ۱۹۶۰۳     | ۱۹         |
| فاصله ساعتی بین توییت خبر جعلی و پیام اصلاحی | ۶۳.۲۴    | ۱۲.۸۴            | ۸۹        | ۱۹         |

\*باتوجه به اجرای طرح در شرایط واقعی، برخی حساب‌های کاربری مطرح با تعداد دنبال‌کننده، دنبال‌شونده و عمر و میزان فعالیت زیاد در طرح حضور داشتند و به این علت انحراف استاندارد برخی متغیرها بالا شد.

با هدف یافتن مؤثرترین نوع پیام اصلاحی بر درگیری کاربران از آزمون رگرسیون لجستیک اسمی دو وجهی (BLR) استفاده شد. برای این کار ابتدا از روش همزمان<sup>۱</sup> و سپس با هدف بهبود مدل و باقی‌ماندن متغیرهای اثرگذارتر، از روش حذف پس‌رو مشروط<sup>۲</sup> کمک گرفته شد. در روش همزمان، در ابتدا برای ارزیابی کل مدل رگرسیونی لجستیک، نتایج مربوط به آزمون اومنی‌بوس<sup>۳</sup> حاکی از آن بود که برازش مدل قابل‌قبول و در سطح کمتر از ۰.۰۵ معنی‌دار بود.

1 enter

2 backward elimination (conditional)

3 omnibus test

جدول ۳. آزمون اومنی بوس برای ارزیابی کلی مدل

| مرحله   | سطح معنی داری | خی دو  | درجه آزادی | سطح معنی داری |
|---------|---------------|--------|------------|---------------|
| مرحله ۱ | ۰.۰۱۳         | ۲۰.۹۷۴ | ۹          | ۰.۰۱۳         |
| بلوک    | ۰.۰۱۳         | ۲۰.۹۷۴ | ۹          | ۰.۰۱۳         |
| مدل     | ۰.۰۱۳         | ۲۰.۹۷۴ | ۹          | ۰.۰۱۳         |

سپس با استفاده از نتایج جدول طبقه بندی<sup>۱</sup> قدرت مدل در تفکیک افراد در طبقات متغیر وابسته تبیین شد. در این بخش دقت مدل در طبقه بندی افراد بالا و معادل ۸۳.۵ درصد بود.

جدول ۴. جدول طبقه بندی

| مورد انتظار |        |                  |            |      |
|-------------|--------|------------------|------------|------|
| مشاهده شده  |        | درگیری           |            | درصد |
| مرحله ۱     | درگیری | نادیده گرفتن (۰) | درگیری (۱) | صحت  |
| ۱           | ۲۷۹    | ۱                | ۹۹.۶       |      |
|             | ۰      | ۵۴               | ۰          |      |
| درصد نهایی  |        |                  |            | ۸۳.۵ |

در نهایت طبق نتایج جدول متغیرهای معادله (جدول ۵)، بازوی ۱ (صرفاً بیان حقیقت) بیشترین تأثیر را بر درگیری کاربران داشت و به صورت معنی داری از بازوی ۲ (بیان توأمان حقیقت و شایعه) تأثیر بیشتری از خود نشان داد ( $p=0.021$ ). بر این اساس با توجه به اینکه معنی داری آماره والد<sup>۲</sup> برای مقایسه بازوی ۱ نسبت به ۲ در سطح خطای کوچکتر از ۰.۰۵ معنی دار است، در این صورت وجود این بازو در مدل مفید و دارای اثر معنی دار است. طبق این نتایج، بین بازوی ۱ و ۳ نیز تفاوت معنی داری وجود نداشت ( $p=0.530$ ). با توجه به اینکه در این مدل، بازوی ۱ پایه مقایسه دو بازوی دیگر قرار گرفت و بر این اساس نسبت دو بازوی ۲ و ۳ مشخص نبود، بار دیگر مدل با پایه قراردادن بازوی ۳ اجرا شد و طبق نتایج آن، علی رغم عملکرد بهتر بازوی ۳ نسبت به ۲، تفاوت معنی داری بین آنها مشاهده نشد ( $p=0.083$ ). همچنین هیچ کدام از ویژگی های کاربران، یعنی تعداد دنبال کننده، تعداد پست، تعداد کل توییت، تعداد کل پسند، عمر حساب کاربری، فاصله بین توییت خبر جعلی و پیام اصلاحی و تعداد دنبال شونده، تأثیر معنی داری بر درگیری کاربران نداشتند.

جدول ۵. جدول متغیرهای معادله

| متغیرها             | آماره B | خطای استاندارد | آماره والد | درجه آزادی | سطح معنی داری | آماره Exp(B) |
|---------------------|---------|----------------|------------|------------|---------------|--------------|
| مرحله ۱             |         |                |            |            |               |              |
| بازوهای آزمایشی     |         |                | ۵.۴۸۴      | ۲          | ۰.۰۶۴         |              |
| بازو (۲ به ۱)       | -۰.۹۳۲  | ۰.۴۰۳          | ۵.۳۵۱      | ۱          | ۰.۰۲۱         | ۰.۳۹۴        |
| بازو (۳ به ۱)       | -۰.۲۲۱  | ۰.۳۵۱          | ۰.۳۹۴      | ۱          | ۰.۵۳۰         | ۰.۸۰۲        |
| تعداد دنبال کننده   | ۰.۰۰۰   | ۰.۰۰۰          | ۱.۸۱۳      | ۱          | ۰.۱۷۸         | ۱.۰۰۰        |
| تعداد پسند          | ۰.۰۰۳   | ۰.۰۰۶          | ۰.۲۸۲      | ۱          | ۰.۵۹۵         | ۰.۹۹۷        |
| تعداد کل توییت      | ۰.۰۰۰   | ۰.۰۰۰          | ۱.۵۱۰      | ۱          | ۰.۲۱۹         | ۱.۰۰۰        |
| تعداد کل پسند       | ۰.۰۰۰   | ۰.۰۰۰          | ۲.۳۰۲      | ۱          | ۰.۱۲۹         | ۱.۰۰۰        |
| عمر حساب کاربری     | ۰.۰۰۰   | ۰.۰۰۰          | ۰.۲۸۵      | ۱          | ۰.۵۹۴         | ۱.۰۰۰        |
| فاصله بین توییت خبر | -۰.۰۱۰  | ۰.۰۱۲          | ۰.۷۰۹      | ۱          | ۰.۴۰۰         | ۰.۹۹۰        |
| جعلی و پیام اصلاحی  |         |                |            |            |               |              |
| تعداد دنبال شونده   | ۰.۰۰۰   |                |            | ۱          |               | ۱.۰۰۰        |

1 classification table

2 wald

|      |         |       |       |   |       |       |
|------|---------|-------|-------|---|-------|-------|
| ثابت | - ۰.۵۷۹ | ۰.۷۹۶ | ۰.۵۲۹ | ۱ | ۰.۴۶۷ | ۰.۵۶۱ |
|------|---------|-------|-------|---|-------|-------|

بعد از مشاهده و تحلیل نتایج در روش همزمان، روش حذف پس‌رو مشروط اجرا شد و در این روش نیز نتایج آزمون اومنی‌بوس حاکی از معنی‌داری نتایج بود ( $p=0.001$ ). همانطور که در جدول ۶ نشان داده شده‌است، نتایج جدول متغیرهای معادله در این روش حاکی از آن است که در مرحله پایانی علاوه بر متغیر بازوهای پژوهشی، متغیر تعداد دنبال‌کننده نیز علی‌رغم اینکه تأثیر معنی‌داری ندارد ( $p=0.068$ )، با این حال متغیر مفید و اثرگذاری در مدل به حساب می‌آید. در این مدل، کماکان بازوی ۱ و ۲ نیز تفاوت معنی‌داری دارند و سطح معنی‌داری آنها نیز بهبود پیدا کرده‌است ( $p=0.019$ ).

جدول ۶. مرحله هفتم و پایانی جدول متغیرهای معادله در روش حذف پس‌رو مشروط

| متغیرها                 | آماره B | خطای استاندارد | آماره والد | درجه آزادی | سطح معنی‌داری | آماره Exp(B) |
|-------------------------|---------|----------------|------------|------------|---------------|--------------|
| مرحله ۷ بازوهای آزمایشی |         |                | ۵.۶۳۷      | ۲          | ۰.۰۶۰         |              |
| بازو (۲ به ۱)           | - ۰.۹۳۷ | ۰.۳۹۸          | ۵.۵۳۴      | ۱          | ۰.۰۱۹         | ۰.۳۹۲        |
| بازو (۳ به ۱)           | - ۰.۲۲۱ | ۰.۳۵۱          | ۰.۴۶۴      | ۱          | ۰.۴۹۶         | ۰.۷۹۰        |
| تعداد دنبال‌کننده       | ۰.۰۰۰   | ۰.۰۰۰          | ۳.۳۲۷      | ۱          | ۰.۰۶۸         | ۱.۰۰۰        |
| ثابت                    | - ۰.۵۷۹ | ۰.۷۹۶          | ۱۷.۰۲۸     | ۱          | ۰.۰۰۰         | ۰.۳۵۱        |

در پایان با هدف بررسی رابطه انواع پیام اصلاحی و انواع درگیری کاربران (شامل پسند پیام اصلاحی، پاسخ به آن، بازنشر آن و حذف توییت اولیه) از آزمون خی دو استفاده شد و با توجه به نتایج جدول ۷ رابطه معنی‌داری بین دو متغیر وجود نداشت ( $p=0.090$ ).

جدول ۷. آزمون خی دو

| آماره | درجه آزادی | سطح معنی‌داری |
|-------|------------|---------------|
| ۸.۰۳۸ | ۴          | ۰.۰۹۰         |
| ۹.۰۹۹ | ۴          | ۰.۰۵۹         |
| ۷.۹۹۹ |            |               |
| ۰.۵۵۲ | ۱          | ۰.۴۵۸         |
| ۳۳۴   |            |               |

## بحث و نتیجه‌گیری

مطالعه حاضر با هدف مقایسه تأثیر علی انواع پیام‌های اصلاحی بر درگیری کاربران فارسی‌زبان منتشرکننده اخبار غلط در سکوی ایکس با این پیام صورت گرفت تا از طریق آن بتوان مؤثرترین پیام اصلاحی را برای مقابله با انتشار اخبار نادرست توسط این کاربران مشخص کرد. این مطالعه در محیط دو قطبی ایکس فارسی‌زبان‌ها و بر روی یک سوژه سیاسی در بافتی ملت‌پسند به لحاظ اجتماعی صورت گرفته‌است. نتایج مطالعه حاکی از آن بود که بازوی اول پژوهش که شامل پیامی مشتمل بر صرف بیان حقیقت ماجرا بود توانست بیش از دو برابر بازوی دوم (که شامل بیان توأمان حقیقت و شایعه بود) و همچنین کمی بیشتر از بازوی سوم (که صرفاً به رد ادعای غلط پرداخته بود) در این کاربران درگیری ایجاد کند و بدین صورت نسبت به بازوی دوم تأثیر بیشتری داشته باشد. بین این دو مدل اصلاح و اعتبارزدایی بین پژوهشگران و متخصصان جهانی روان‌شناسی اخبار جعلی تفاوت نظر وجود داشت و مطالعه حاضر اولین مطالعه‌ای است که بصورت میدانی توانست تأثیر این دو مدل را با یکدیگر مقایسه کرده و نشان دهد حداقل در متغیر درگیری، مدل صرفاً بیان حقیقت از مدل چهار مرحله‌ای اعتبارزدایی کارآمدتر است.

احتمالاً تفاوت تأثیر دو بازوی ۱ و ۲ را می‌توان به این عوامل نسبت داد؛ کوتاه‌تر بودن بازوی اول و به تبع جلب توجه و درگیری بیشتر، کمتر درگیرکننده بودن بازوی دوم به علت طولانی‌بودن پیام و بیان حقایق کمتر شنیده‌شده در بازوی اول که برای مخاطب بدیع‌تر است.



در مقایسه با مطالعه مارتل و همکاران (۲۰۲۱) که شبیه به مطالعه حاضر بود و نتایج آن بیانگر این بود که محتوای پیام اصلاحی تأثیری بر احتمال درگیری کاربران ندارد، این مطالعه توانست خلاف آن را نشان دهد. همچنین این مطالعه بیان داشت ویژگی‌های مختلف کاربران تأثیری بر درگیری آنها با پیام‌های اصلاحی ندارد و هیچ رابطه‌ای نیز بین انواع پیام‌های اصلاحی و انواع درگیری کاربران مشاهده نشد.

به لحاظ عملی این مطالعه یعنی مداخله اصلاح اجتماعی قابلیت کاربردی‌سازی در دنیای واقعی را دارد و تمام دغدغه‌مندان، اهالی رسانه و سیاست‌گذاران بخش‌های مختلف کشور می‌توانند از یافته‌های این مطالعه برای مقابله درست و مبتنی بر شواهد علی با اخبار جعلی منتشرشده در رسانه‌های اجتماعی استفاده کنند؛ یعنی برای اعتبارزدایی موج‌های مختلف خبر جعلی و اصلاح کاربرانی که اقدام به انتشار این اخبار می‌کنند، صرفاً به بیان حقایق بپردازند.

این مطالعه دارای چند محدودیت بود؛ اولاً، باتوجه به محدودیت‌های ماه‌های اخیر ایکس در دسترسی به اطلاعات و همچنین فعالیت کاربران و علی‌رغم اینکه در ابتدا نمونه‌ای بیش از ۱۰۰۰ نفره برای اجرای مداخله در نظر گرفته شده بود، مداخله پایانی ناچاراً بر روی نمونه‌ای کوچکتر اجرا شد و از این حیث اولین محدودیت طرح تعداد پایین نمونه بود و این موضوع احتمالاً علت معنی‌دارنشدن اثر تعدادی از متغیرهای طرح است و همچنین ممکن است قدرت آماری لازم برای نشان‌دادن رابطه علی بین متغیرها را فراهم نسازد. در ثانی، این مطالعه صرفاً بر روی یک خبر جعلی انجام شد و به‌علت تکیه بر یک خبر و یک گروه مخاطب، نتایج آن قابلیت تعمیم به سایر گروه‌های کاربران ایکس را ندارد. ثالثاً، به‌علت رونق‌داشتن سایت‌های راستی‌آزمایی بی‌طرف و فعال در کشور، امکان فعالیت بر روی تعداد بیشتری خبر جعلی و همچنین بررسی متغیرهای دیگر چون انتشار اخبار غلط وجود نداشت و راستی‌آزمایی خبر مربوط به فوت آقای جواد روحی نیز صرفاً بر اساس اعلام‌نظر دستگاه‌های رسمی کشور صورت گرفت. محدودیت آخر نیز کمبود اطلاعات بیشتر چون سن و جنسیت کاربران ایکس است که استخراج آنها نیازمند مدل‌ها و روش‌های پیچیده یادگیری ماشین.

در پایان چند پیشنهاد برای انجام مطالعات آینده ارائه می‌شود؛ اولاً، طبق نتایج این مطالعه نرخ درگیری کاربران با پیام اصلاحی کماکان بسیار پایین است و مطالعات بعدی باید با پرداخت به سایر متغیرها به دنبال افزایش کلی این عدد باشند. در اینجا می‌توان به متغیرهایی چون جنسیت و هویت حزبی کاربر اصلاح‌کننده، زمان ارسال پیام، تعداد کاربران اصلاح‌کننده و ارسال پیام به‌صورت عمومی یا خصوصی اشاره کرد. ثانیاً، مطالعات بعدی می‌بایست به تعداد خبر بیشتر و با گروه‌های مخاطب متفاوت بپردازند تا تأثیر اصلاح اجتماعی بر گروه‌های مختلف و در موضوعات متفاوت مورد بررسی قرار گیرد. ثالثاً، علاوه بر متغیر درگیری می‌بایست متغیرهای انتشار و پذیرش مطالعه شوند تا درک کامل‌تری از باورها و رفتارهای مرتبط با اخبار جعلی حاصل شود. رابعاً، مداخله اصلاح اجتماعی در سایر سکوها اجتماعی پرطرفدار چون اینستاگرام و همچنین پیام‌رسان‌ها اجرا شود. در پایان با اجرای این روش بر روی نمونه بزرگی از کاربران و استفاده از یادگیری ماشین می‌توان از نتایج تحلیل پیش‌بین به پیش‌بینی اثرگذاری پیام‌های اصلاحی بر گروه‌های مختلف مخاطب پرداخت.

## منابع

- خبرگزاری ایرنا (۱۴۰۲، ۹ شهریور). «جواد روحی» قبل از ورود به زندان سابقه تشنج و بستری در بیمارستان داشته است. بازیابی شده از <https://irna.ir/xjNmht>
- خبرگزاری میزان (۱۴۰۲، ۱۰ شهریور). جواد روحی به چه جرمی در زندان بود؟ از هتاکي به قرآن تا تخریب اموال عمومی. بازیابی شده از <https://www.mizanonline.ir/00Jr5T>
- Bode, L., & Vraga, E. K. (2018). See something, say something: Correction of global health misinformation on social media. *Health Communication*, 33(9), 1131-1140. <https://doi.org/10.1080/10410236.2017.1331312>
- Chan, M. P. S., Jones, C. R., Hall Jamieson, K., & Albarracín, D. (2017). Debunking: A meta-analysis of the psychological efficacy of messages countering misinformation. *Psychological Science*, 28(11), 1531-1546. <https://doi.org/10.1177/0956797617714579>
- Ecker, U. K., Lewandowsky, S., Cook, J., Schmid, P., Fazio, L. K., Brashier, N., ... & Amazeen, M. A. (2022). The psychological drivers of misinformation belief and its resistance to correction. *Nature Reviews Psychology*, 1(1), 13-29. <https://doi.org/10.1038/s44159-021-00006-y>
- Ecker, U. K., Lewandowsky, S., & Tang, D. T. (2010). Explicit warnings reduce but do not eliminate the continued influence of misinformation. *Memory & Cognition*, 38, 1087-1100. <https://doi.org/10.3758/MC.38.8.1087>
- Freeman, D., Waite, F., Rosebrock, L., Petit, A., Causier, C., East, A., ... & Lambe, S. (2022). Coronavirus conspiracy beliefs, mistrust, and compliance with government guidelines in England. *Psychological Medicine*, 52(2), 251-263. <https://doi.org/10.1017/S0033291720001890>

## The Effect of Correction Intervention on Engagement of Users Sharing Fake News on X (Twitter)

- Johnson, N. F., Velásquez, N., Restrepo, N. J., Leahy, R., Gabriel, N., El Oud, S., ... & Lupu, Y. (2020). The online competition between pro-and anti-vaccination views. *Nature*, 582(7811), 230-233. <https://doi.org/10.1038/s41586-020-2281-1>
- Jolley, D., & Paterson, J. L. (2020). Pylons ablaze: Examining the role of 5G COVID-19 conspiracy beliefs and support for violence. *British Journal of Social Psychology*, 59(3), 628-640. <https://doi.org/10.1111/bjso.12394>
- Kozyreva, A., Lewandowsky, S., & Hertwig, R. (2020). Citizens versus the internet: Confronting digital challenges with cognitive tools. *Psychological Science in the Public Interest*, 21(3), 103-156. <https://doi.org/10.1177/1529100620946707>
- Lazer, D. M., Baum, M. A., Benkler, Y., Berinsky, A. J., Greenhill, K. M., Menczer, F., ... & Zittrain, J. L. (2018). The science of fake news. *Science*, 359(6380), 1094-1096. <https://doi.org/10.1126/science.aao2998>
- Lewandowsky, S., Cook, J., Ecker, U. K. H., Albarracín, D., Amazeen, M. A., Kendeou, P., Lombardi, D., Newman, E. J., Pennycook, G., Porter, E. Rand, D. G., Rapp, D. N., Reifler, J., Roozenbeek, J., Schmid, P., Seifert, C. M., Sinatra, G. M., Swire-Thompson, B., van der Linden, S., Vraga, E. K., Wood, T. J., Zaragoza, M. S. (2020). The Debunking Handbook 2020. <https://doi.org/10.17910/b7.1182>.
- Lewandowsky, S., Ecker, U. K., & Cook, J. (2017). Beyond misinformation: Understanding and coping with the “post-truth” era. *Journal of Applied Research in Memory and Cognition*, 6(4), 353-369. <https://doi.org/10.1016/j.jarmac.2017.07.008>
- Lewandowsky, S., Ecker, U. K., Seifert, C. M., Schwarz, N., & Cook, J. (2012). and successful debiasing. *Psychological science in the public interest*, 13(3), 106-131. <https://doi.org/10.1177/1529100612451018>
- Loomba, S., de Figueiredo, A., Piatek, S. J., de Graaf, K., & Larson, H. J. (2021). Measuring the impact of COVID-19 vaccine misinformation on vaccination intent in the UK and USA. *Nature Human Behaviour*, 5(3), 337-348. <https://doi.org/10.1038/s41562-021-01056-1>
- Margolin, D. B., Hannak, A. & Weber, I. Political fact-checking on Twitter: When do corrections have an effect? *Political Communication* 35, 196-219 (2018). <https://doi.org/10.1080/10584609.2017.1334018>
- Martel, C., Mosleh, M., & Rand, D. G. (2021). You're definitely wrong, maybe: Correction style has minimal effect on corrections of misinformation online. *Media and Communication*, 9(1), 120-133. <https://doi.org/10.17645/mac.v9i1.3519>
- Mosleh, M., Pennycook, G., & Rand, D. G. (2022). Field experiments on social media. *Current Directions in Psychological Science*, 31(1), 69-75. <https://doi.org/10.1177/09637214211054761>
- NATO Strategic Communications Centre of Excellence (2021). Inoculation theory and misinformation. Retrieved from: <https://stratcomcoe.org/publications/inoculationtheory-and-misinformation/217>
- Pennycook, G., & Rand, D. G. (2021a). The psychology of fake news. *Trends in Cognitive Sciences*, 25(5), 388-402. <https://doi.org/10.1016/j.tics.2021.02.007>
- Pennycook, G., and Rand, D.G. (2021b) Examining false beliefs about voter fraud in the wake of the 2020 Presidential Election. *Harvard Kennedy Sch. Misinformation Rev.* 2, 1–19. <https://doi.org/10.37016/mr-2020-51>
- Perrin, A.(2015). Social media usage. *Pew Research Center* , 52-68 [https://www.secretintelligenceservice.org/wp-content/uploads/2016/02/PI\\_2015-10-08\\_Social-Networking-Usage-2005-2015\\_FINAL.pdf](https://www.secretintelligenceservice.org/wp-content/uploads/2016/02/PI_2015-10-08_Social-Networking-Usage-2005-2015_FINAL.pdf)
- Politico (2022, december 3). How Ukraine Won The #LikeWar. Retrieved from <https://www.politico.com/news/magazine/2022/03/12/ukraine-russia-information-warfare-likewar00016562>
- Schwarz, N., Newman, E., & Leach, W. (2016). Making the truth stick & the myths fade: Lessons from cognitive psychology. *Behavioral Science & Policy*, 2(1), 85-95. <https://doi.org/10.1177/237946151600200110>
- Stewart, A. J., Mosleh, M., Diakonova, M., Arechar, A. A., Rand, D. G., & Plotkin, J. B. (2019). Information gerrymandering and undemocratic decisions. *Nature*, 573(7772), 117-121. <https://doi.org/10.1038/s41586-019-1507-6>
- Twitter Blog (2022). Our approach to the 2022 US midterms. Retrieved from [https://blog.twitter.com/en\\_us/topics/company/2022/-our-approach-to-the-2022-us-midterms](https://blog.twitter.com/en_us/topics/company/2022/-our-approach-to-the-2022-us-midterms)
- Van Der Linden, S. (2022). Misinformation: susceptibility, spread, and interventions to immunize the public. *Nature medicine*, 28(3), 460-467. <https://doi.org/10.1038/s41591-022-01713-6>
- Vasudeva, F., & Barkdull, N. (2020). WhatsApp in India? A case study of social media related lynchings. *Social Identities*, 26(5), 574-589. <https://doi.org/10.1080/13504630.2020.1782730>
- Vosoughi, S., Roy, D., & Aral, S. (2018). The spread of true and false news online. *Science*, 359(6380), 1146-1151. <https://doi.org/10.1126/science.aap9559>
- Vraga, E. K., & Bode, L. (2017). Using expert sources to correct health misinformation in social media. *Science Communication*, 39(5), 621-645. <https://doi.org/10.1177/107554701773177>
- Walter, N., & Murphy, S. T. (2018). How to unring the bell: A meta-analytic approach to correction of misinformation. *Communication Monographs*, 85(3), 423-441. <https://doi.org/10.1080/03637751.2018.1467564>
- Wittenberg, C., Berinsky, A. J., Persily, N., & Tucker, J. A. (2020). Misinformation and its correction. *Social media and democracy: The State of The Field, Prospects for Reform*, 163. [https://www.opolisci.com/wp-content/uploads/pdf-front/Social\\_Media\\_and\\_Democracy.pdf#page=183](https://www.opolisci.com/wp-content/uploads/pdf-front/Social_Media_and_Democracy.pdf#page=183)