



Sharif University of Technology



Data Science and Machine Learning Lab

Life as a Data Scientist

System Analysis and Design

S.M.F. Sani

Data Science and Machine Learning Lab (DML)
Department of Computer Engineering, Sharif University of Technology
Oct 2024

Introduction

Introduction

About Me



Introduction (Cont.)


About Me



What is this machine learning thing...

Machine Learning

Magic of our era!



Machine Learning

Magic of our era!



Cyberpunk Style Mercedes Benz in Night City



super realistic portrait of an Iranian model, little smile, rainy day, standing in crossway



A blonde woman with elvish ears wearing green dress that has silver buttons puts flower hairpin in her hair sitting on a wooden chair inside of wooden cottage.

Applications (Iran)

Digital Advertising

پخش زندهاپلیکیشن ورزش سهپیش بینیگزارش تصویریاخبار ورزشیثبت نظراپادکستتبلیغاتسوره‌های شماشنبه ۲۱ مهر - ۱۵:۳۳جستجوورود

ورزش سهصفحه اصلیجدول لیگ برترجام حذفیویدیو روزنامه نقل و انتقالاتنتایج زنده

تماشا کن

فینال مسترالمپیا ۲۰۲۴

خدمات یکپارچه پیامک

خرید آنلاین طلا با کارمزد صفر ثبت نام رایگان >>

با پرداخت اعتباری از تکنولایف، الان بخر بعدا پرداخت کن! < خرید

AFR@NET

هیئت مدیره اعاده حیثیت می‌کند؛ شکایت دسته‌جمعی پرسپولیس از بیرانوند!

اعضای هیئت مدیره پرسپولیس با اعلام شکایت از علیرضا بیرانوند اقدام حقوقی مهمی را در تحولات مربوط به پرونده دروازه‌بان سابق خود انجام داد.

۱۲۳۴۵۶۷۸

تیر دو برنابئو نه، نوکمپ میزبان فینال جام جهانی ۲۰۳۰!

هرچند سانتیاگو برنابئو را میزبان احتمالی فینال جام جهانی ۲۰۳۰ می‌دانند، ولی در بارسلونا معتقدند این اتفاق رخ نخواهد...

۱۲۳۴۵۶۷

جدیدترین‌ها

پربازدیدترین‌ها

پربحث‌ترین‌ها

داخلی

خارجی

ویدیو

سوادکود

جاباما

پیش شماره ۰۹۹۱۲

جستجو در بازی‌ها و برنامه‌ها

پیشنهادهای بیشتر • آگهی

استپ | Snapp | بانک ولی | نویتکس: خرید | بیت کوین و ارز دی... | دوست‌داشتنی | رایگان

حذف همه

جستجوهای قبلی

تزدیکا

15:11 34%

اخبار برگزیده

تازه ترینویدئوپربازدیدترینپربحث ترین

از حقوق ماهانه‌ت سود بگیر همیشه نقد، با سود ۲۶ درصد کارت رایگان

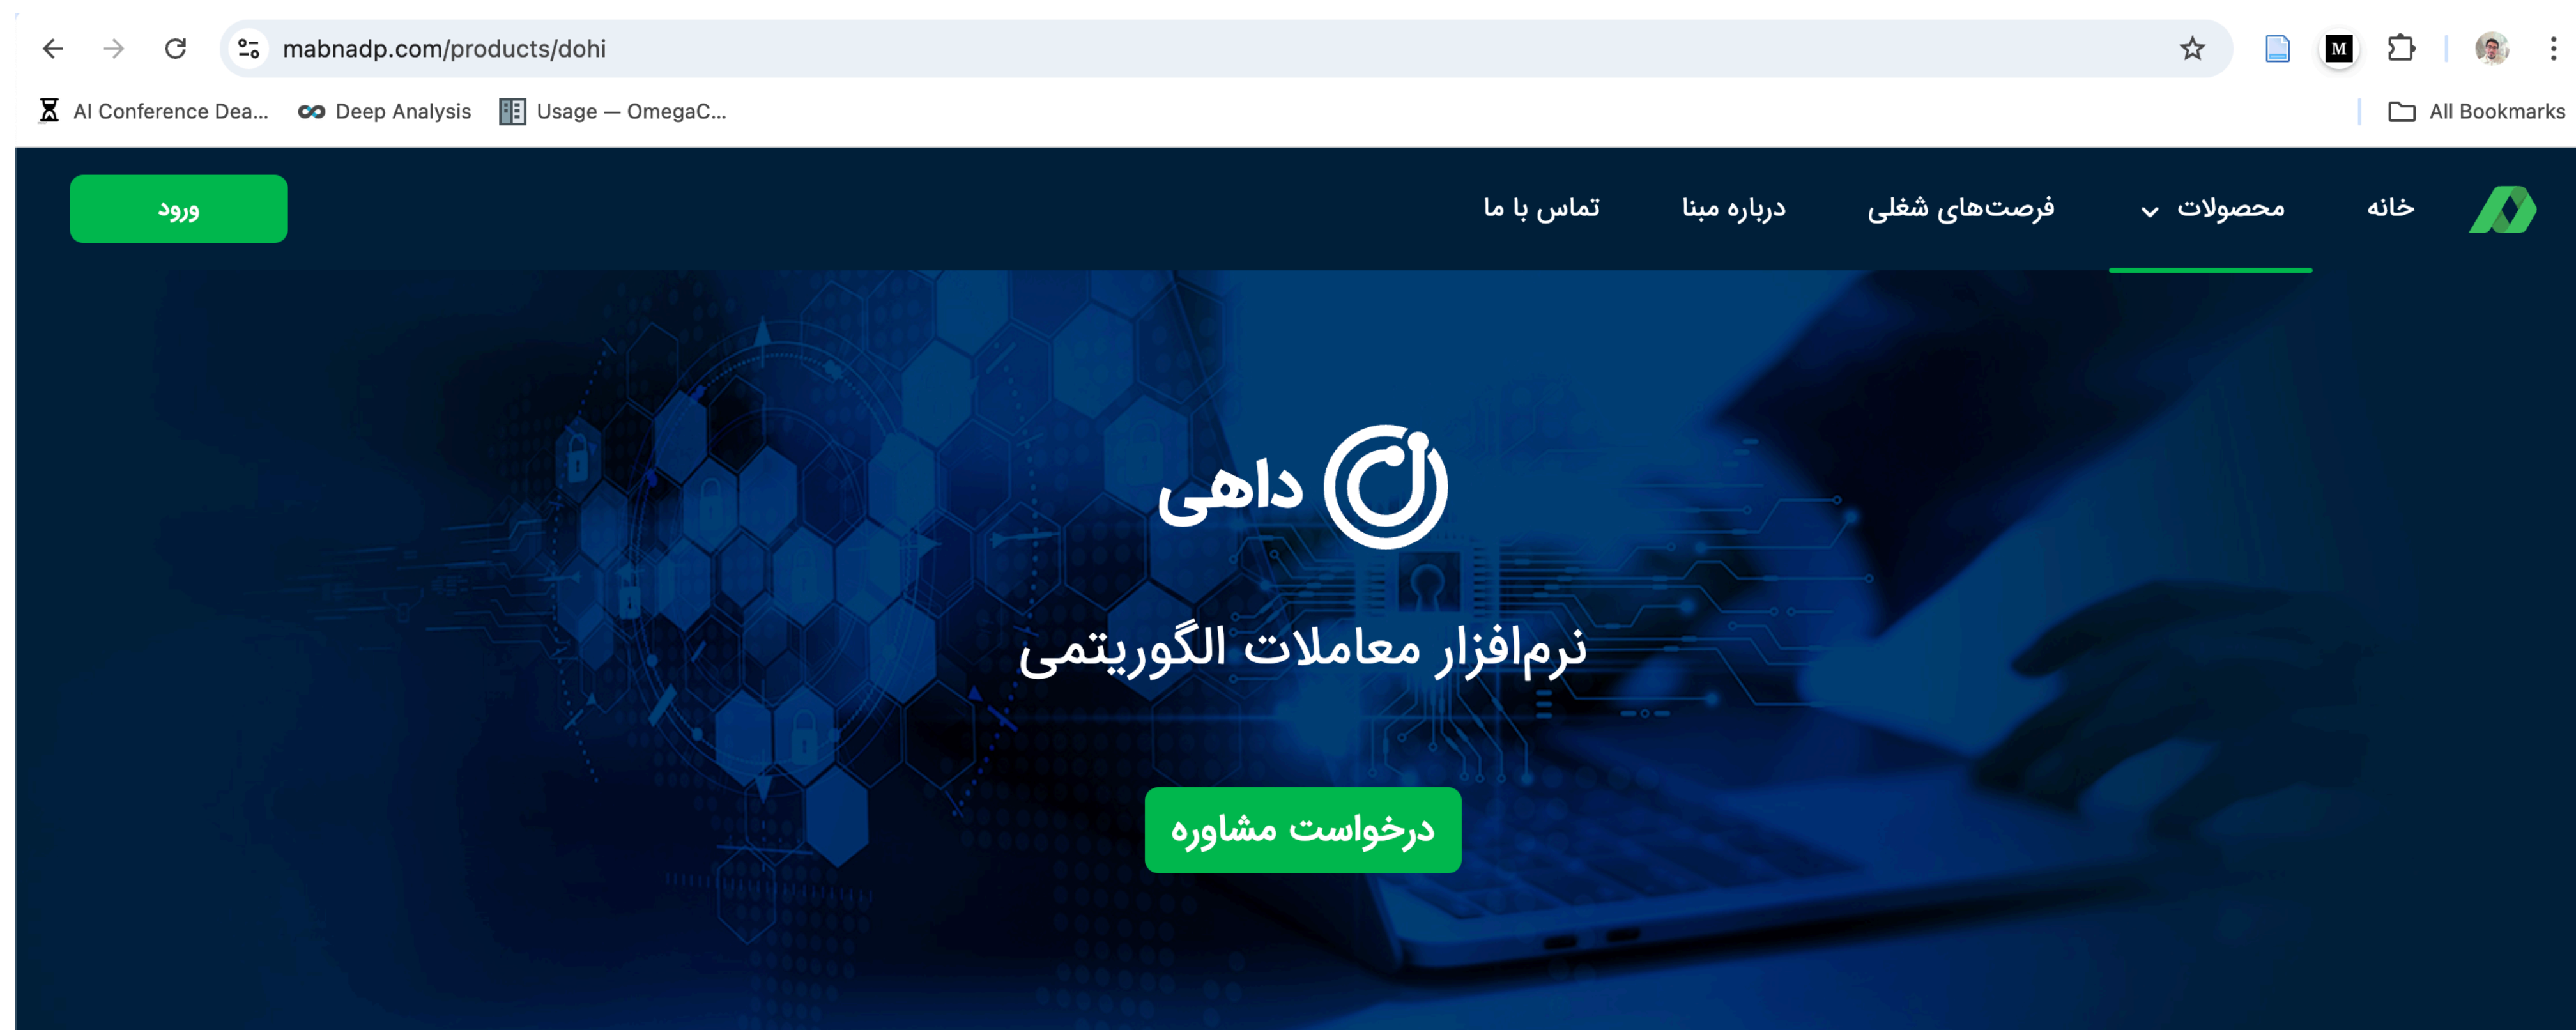
طوفان مهمدی در المپیک با شکست قاطع برنده قهرمان جهان ایسنا | ۱۴:۴۶ - ۱۴۰۳/۰۵/۱۷

محرومیت تاریخی برای ستاره والیبال ایران ورزش ۳ | ۱۴:۳۱ - ۱۴۰۳/۰۵/۱۷

سمیعی: کاکوتا به ایران می‌آید تسنیم | ۱۴:۳۰ - ۱۴۰۳/۰۵/۱۷

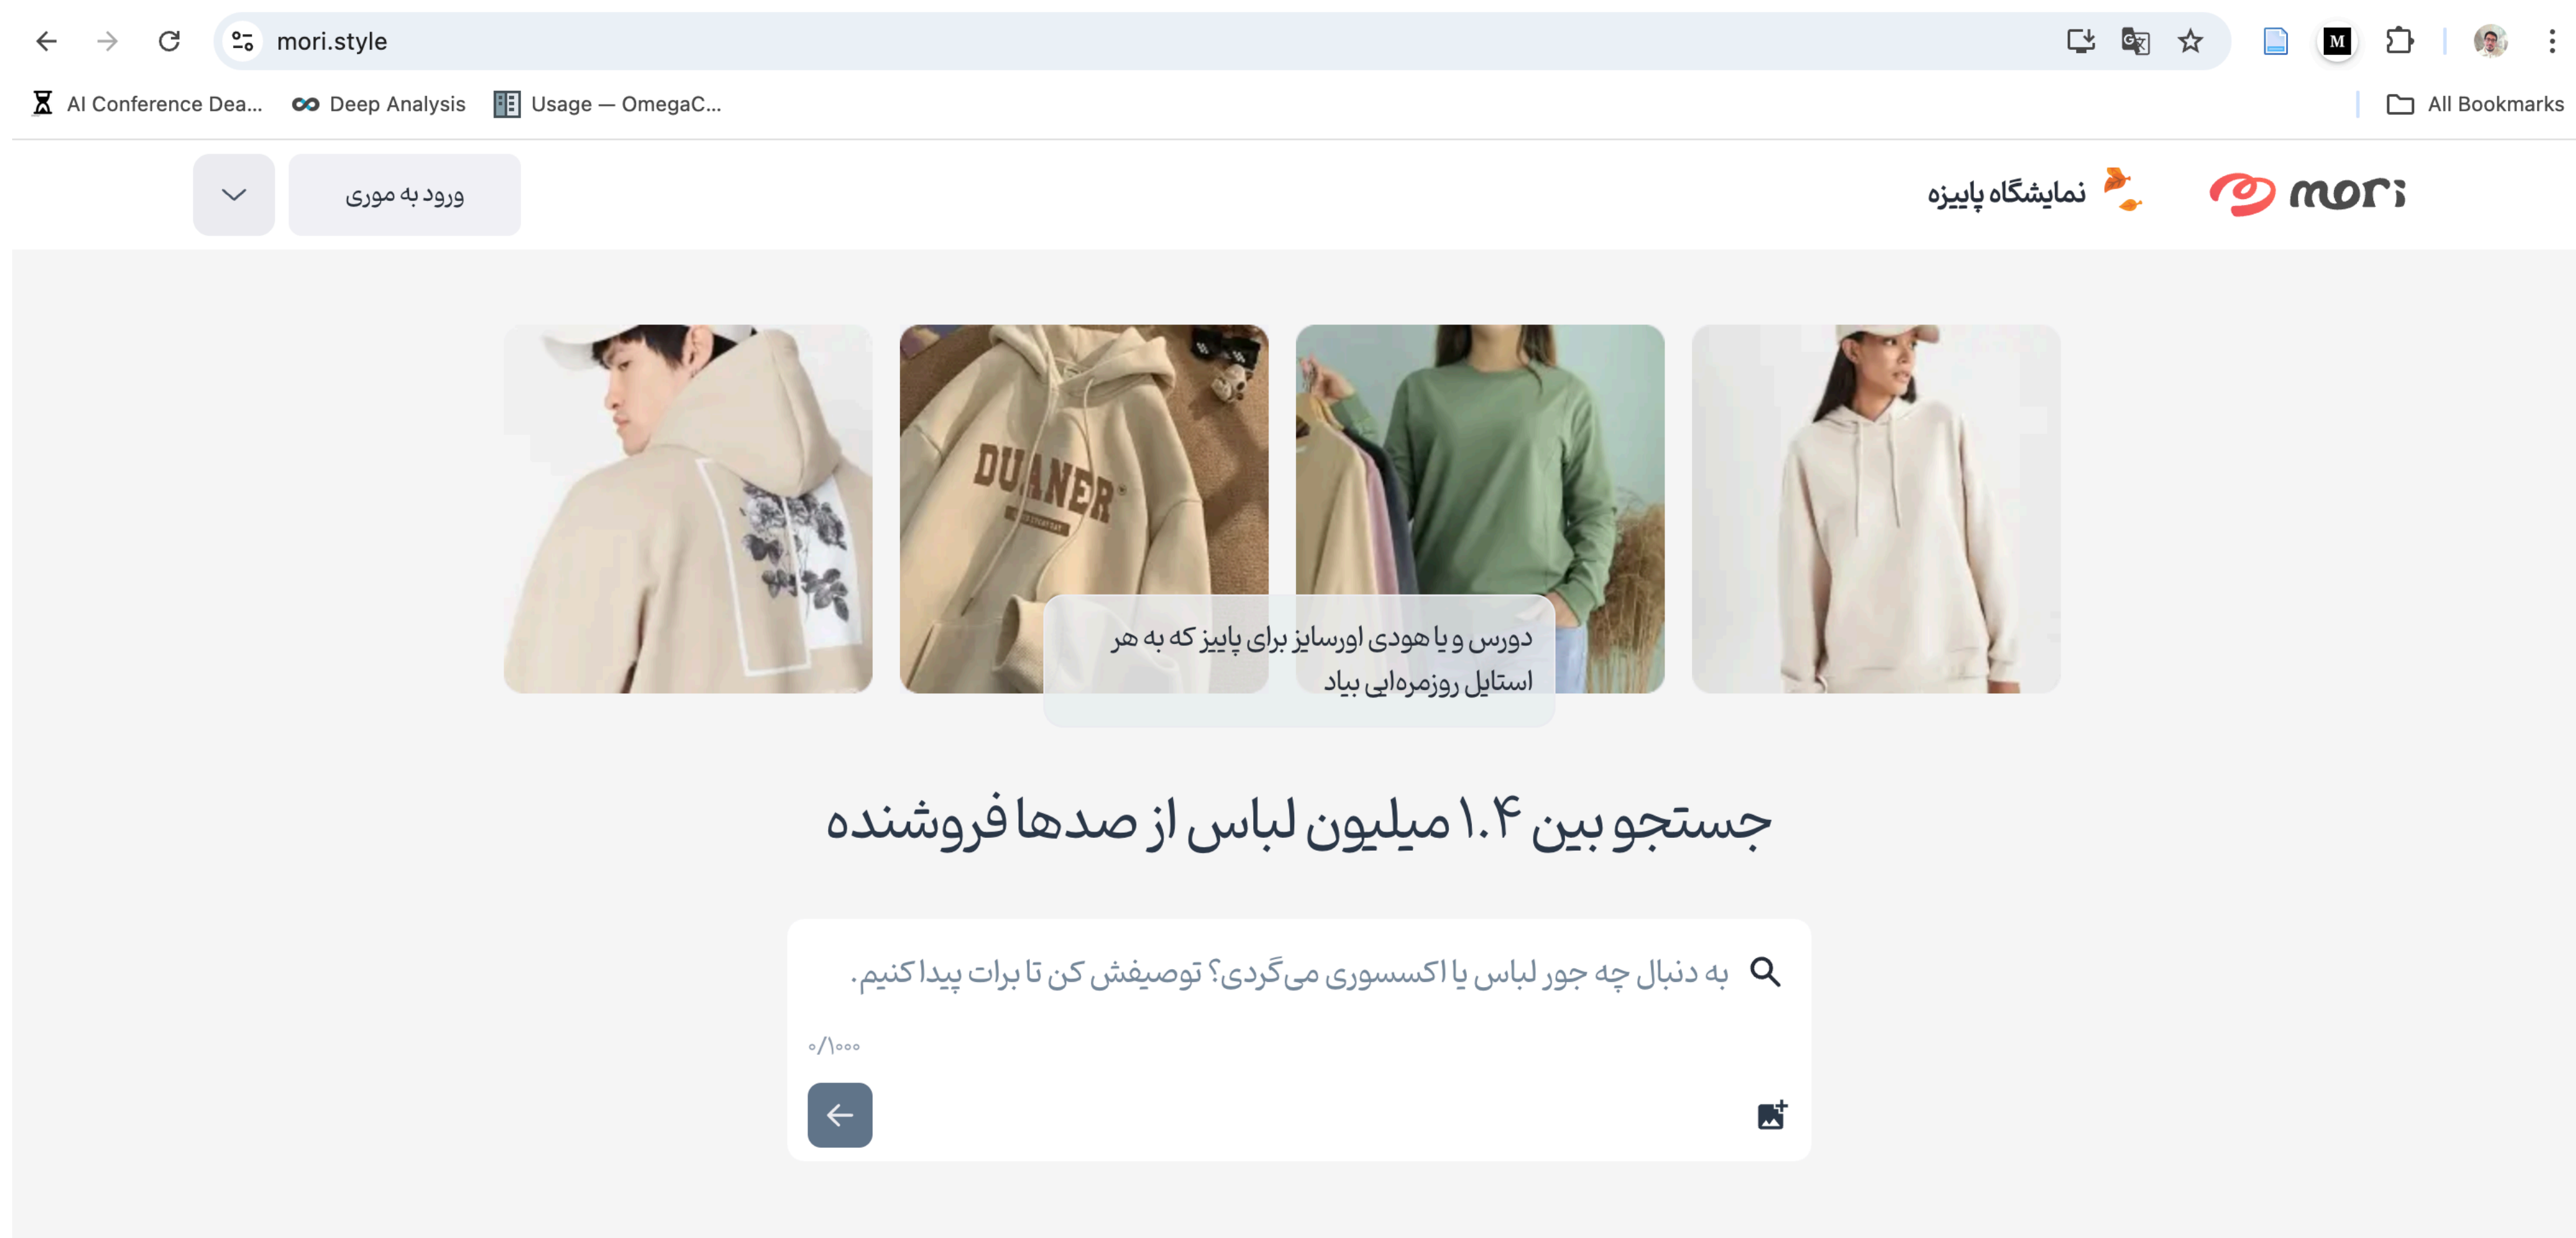
Applications (Iran)

Trade



Applications (Iran)

Product Search



Applications (Iran)

Navigation

دانلود

نشان | نقشه و مسیر یاب

نشان نقشه‌ی شهرهای ایران

نسخه ۱۲.۵.۳

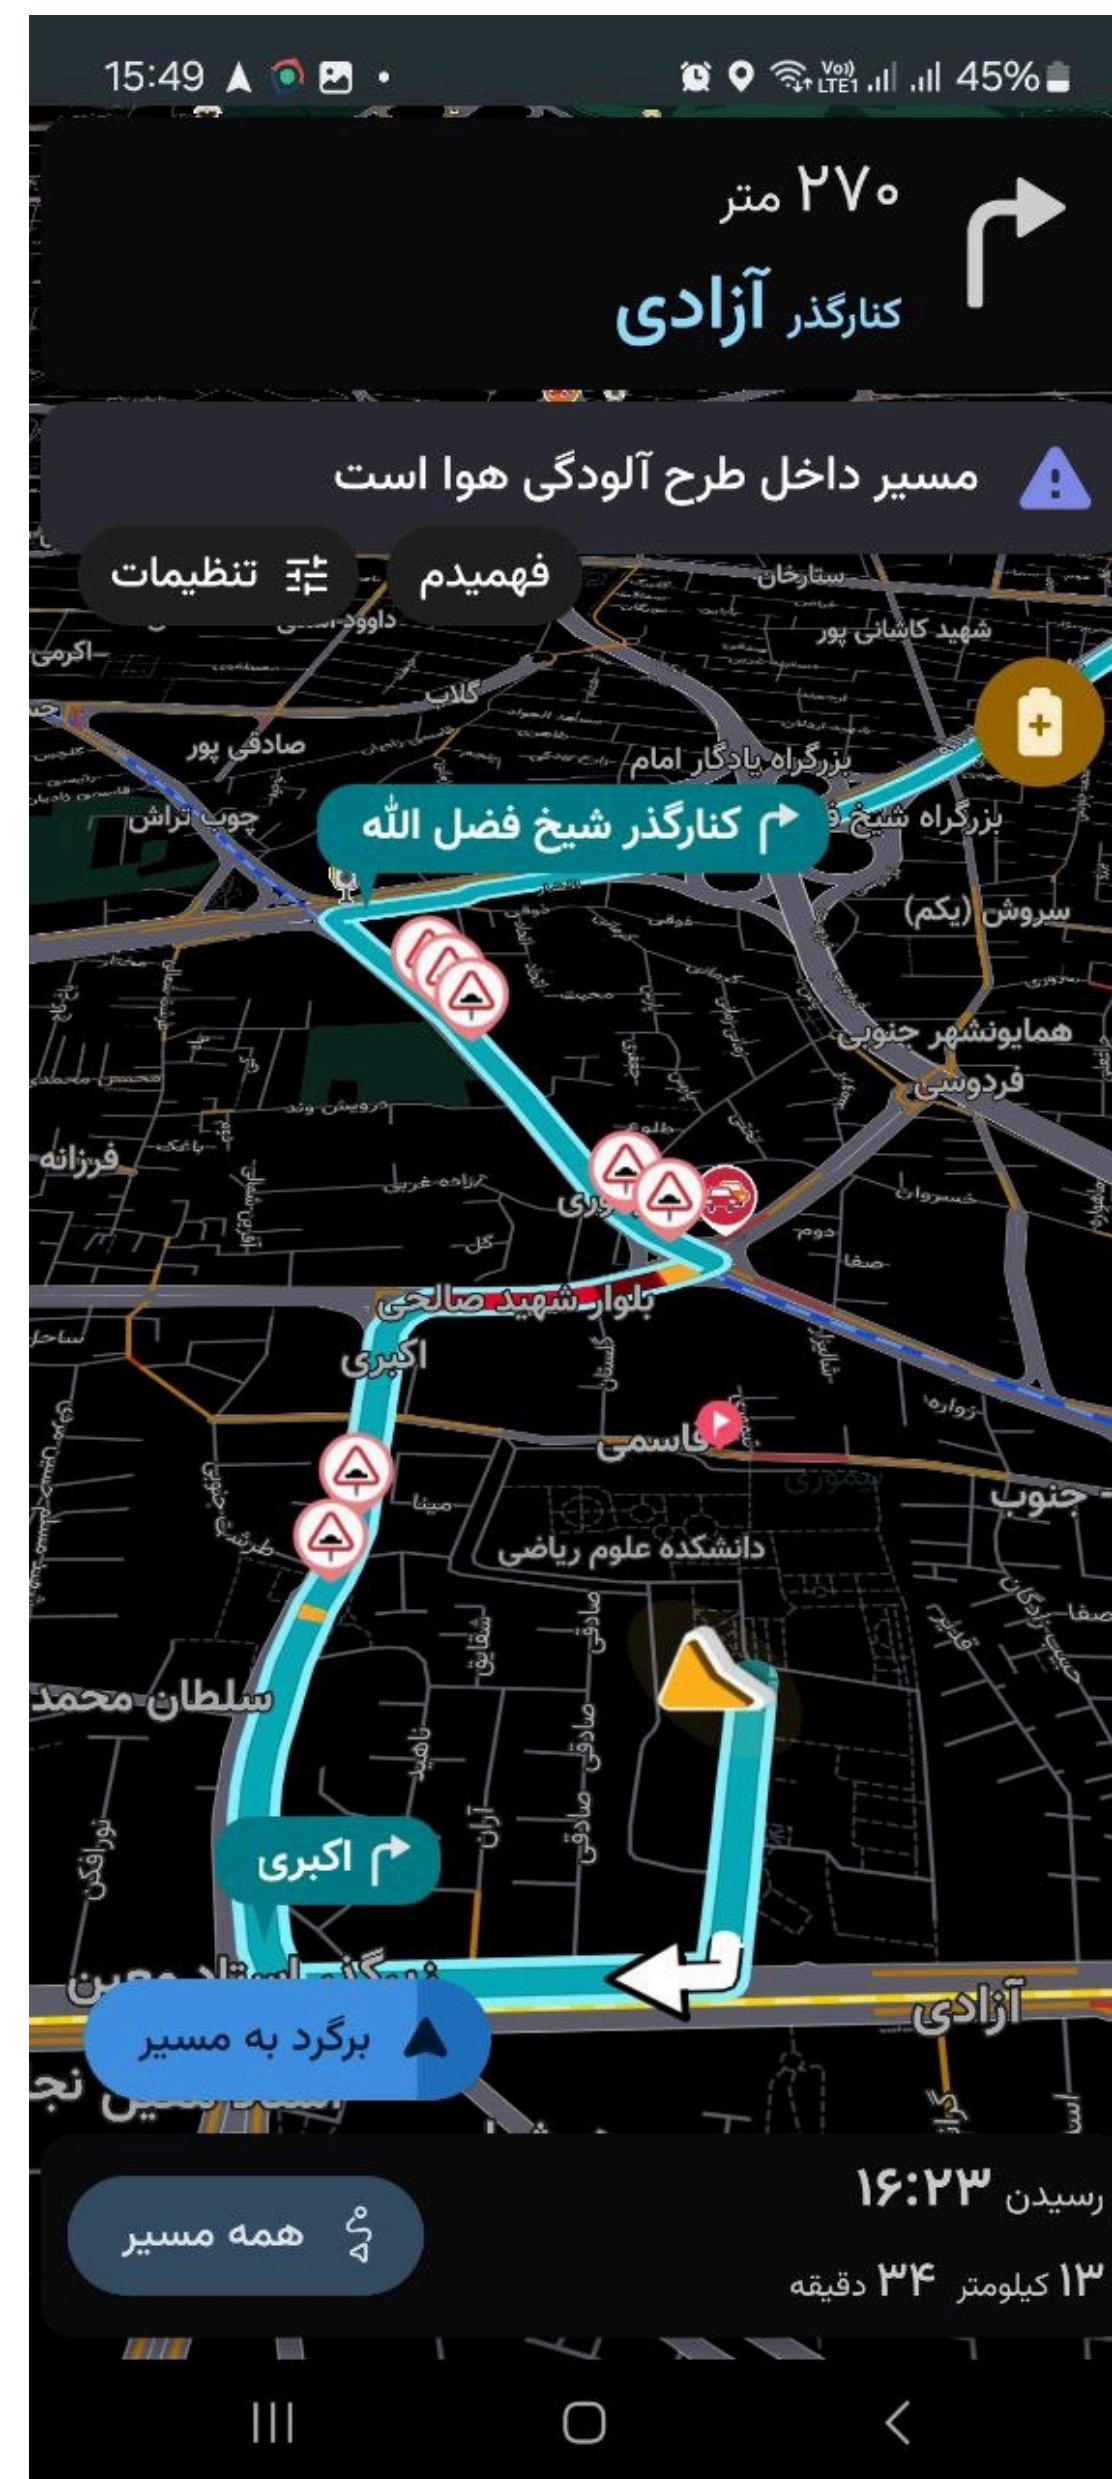
۲۰+ میلیون نصب

۴.۴ ☆ از ۱۴۵,۳۵۲ رأی

رفت و آمد دسته‌بندی

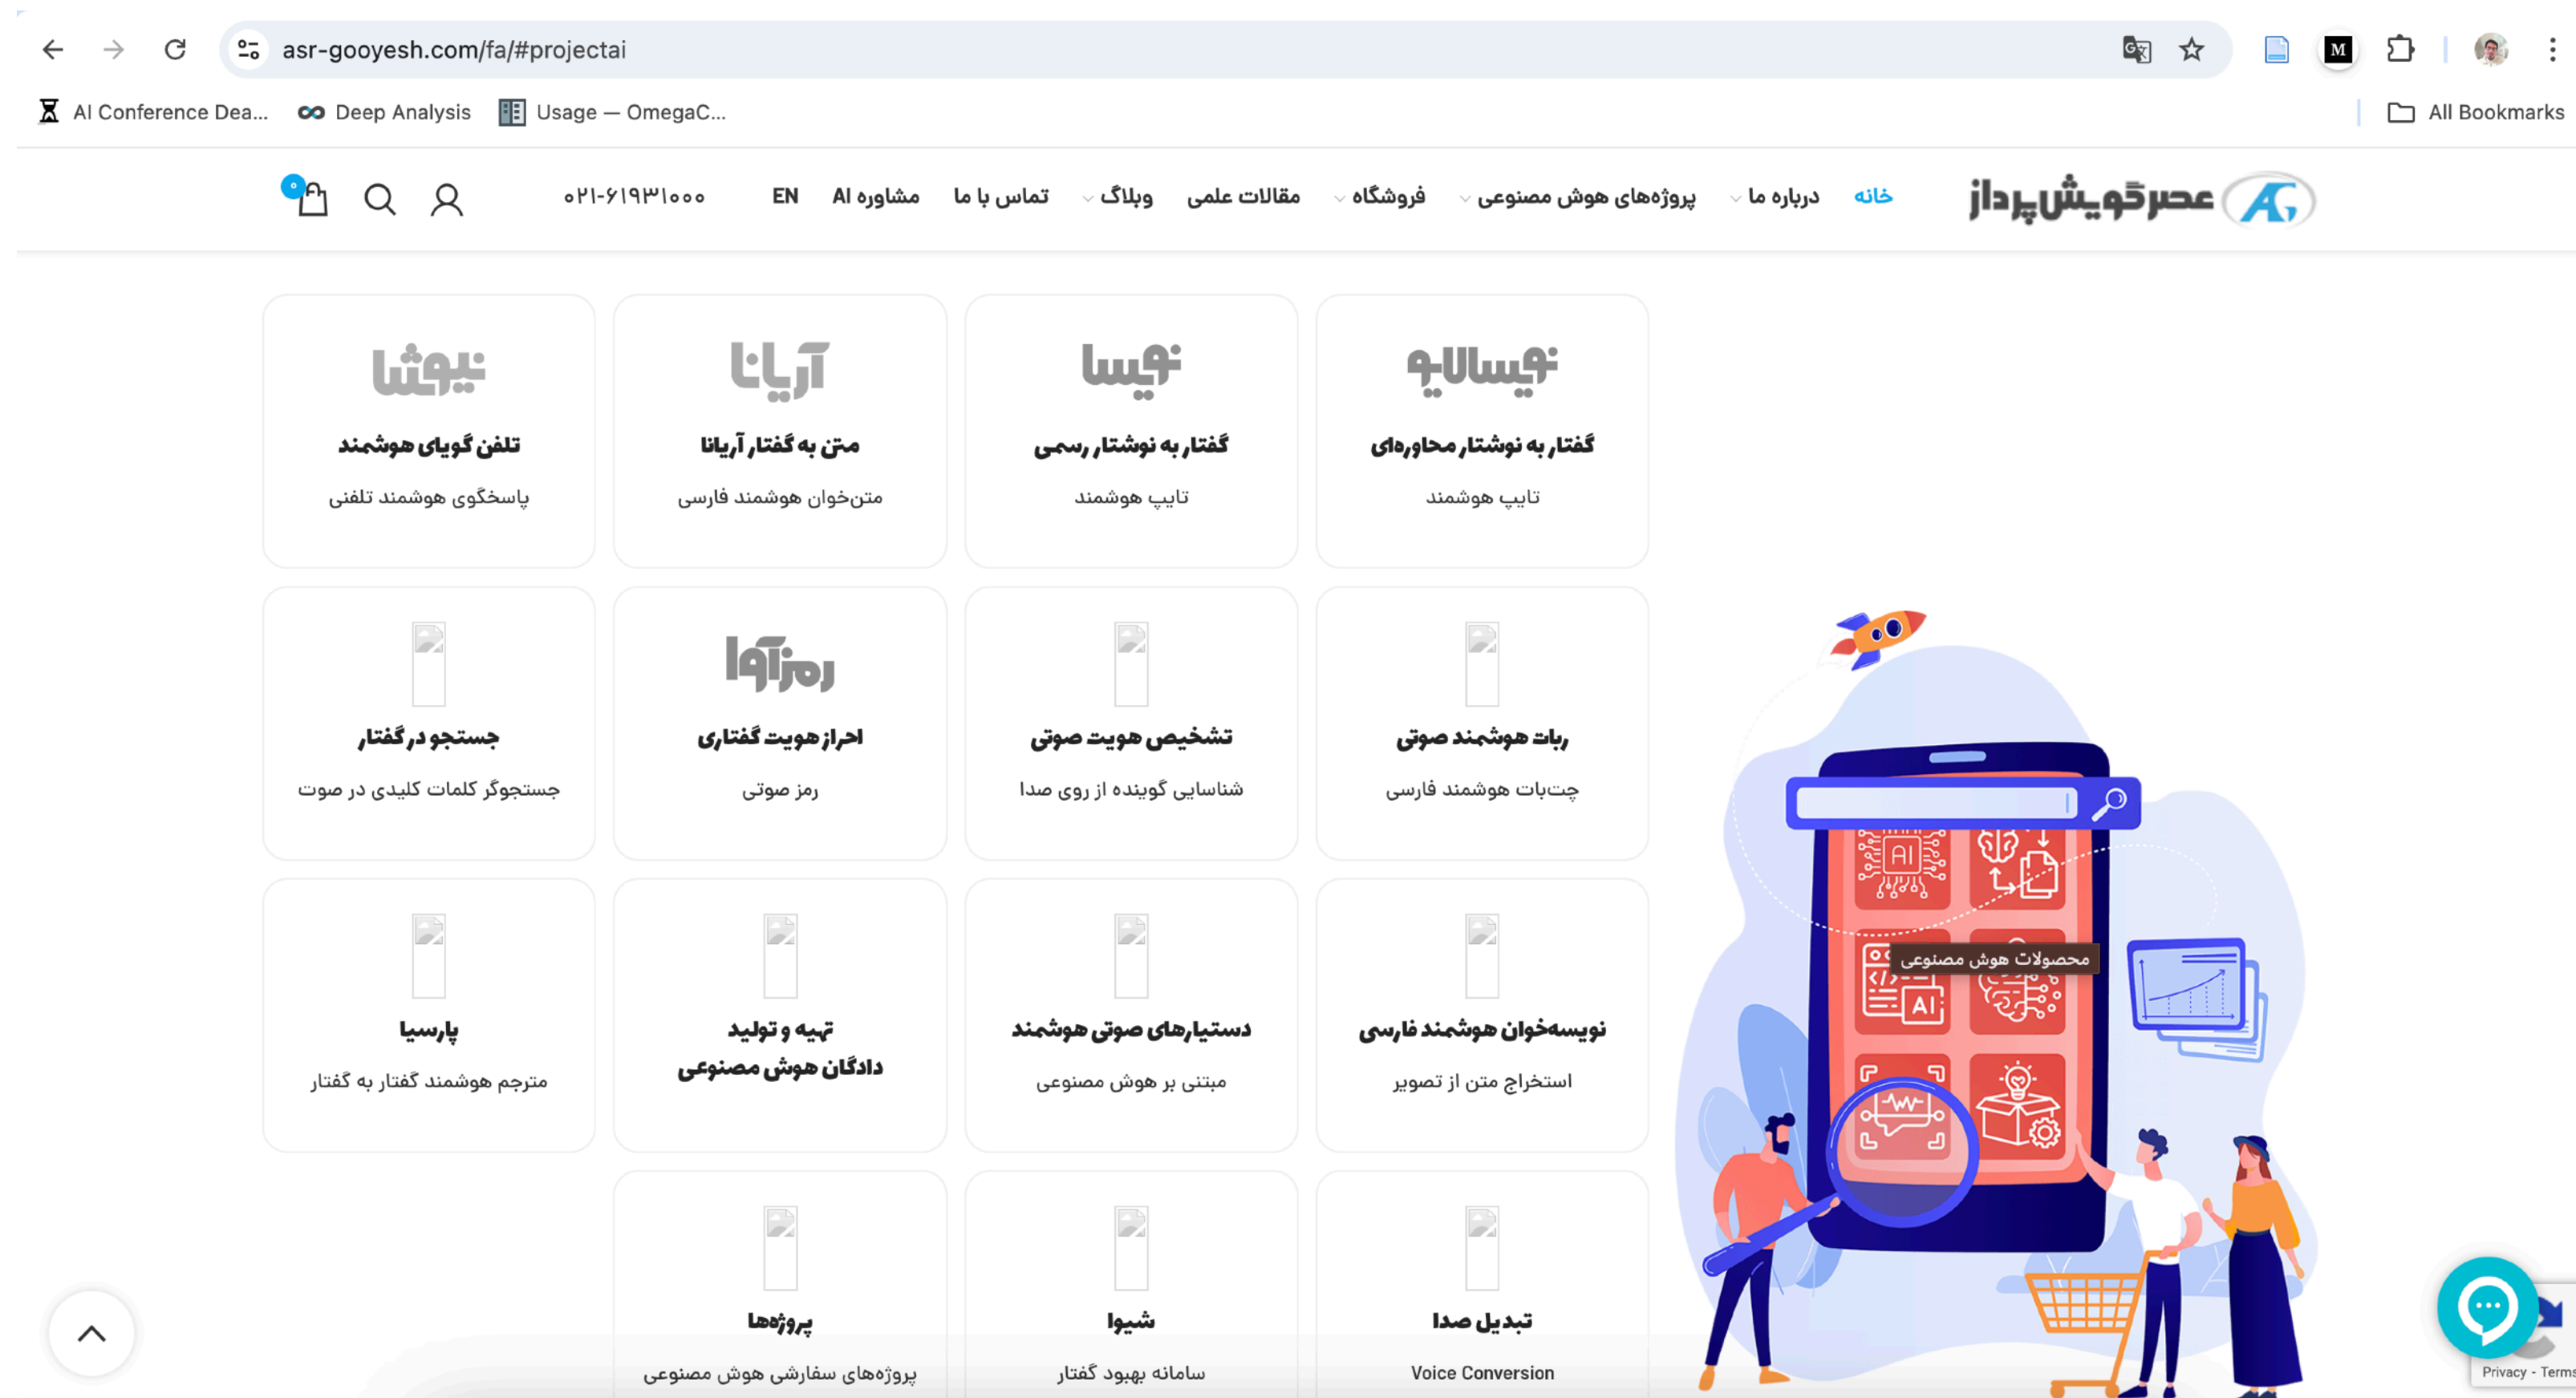
۲۸ مگابایت حجم

۱۸ مرداد ۱۴۰۳ آخرین بروزرسانی



Applications (Iran)

Speech Processing



Academia vs Industry

Academia Vs Industry

Money




Team of Multi Skill Experts



Infrastructure

Academia Vs Industry

Team Work, Communication (Maybe our Problem)




Academia Vs Industry

Priorities, Deadlines



"The only way to do great work is to love what you do. If you haven't found it, keep looking. Don't settle."

- Steve Jobs



SOMEONE IN THEIR 40S WHO'S STILL IN GRAD SCHOOL



Academia Vs Industry

Importance of Data



Facebook and Google Are the New Data Brokers

By Chris Hoofnagle | University of California, Berkeley

They claim not to sell data, but Facebook and Google have paid developers with data. This selling of your personal data is central to platform economics. Could quality signals change the terms of the bargain?

"We do not sell your personal information to anyone"
[<https://safety.google/privacy/ads-and-data/>] – Google, Ads and Data Webpage

"No, we don't sell any of your information to anyone and we never will."
[<https://www.facebook.com/help/152637448140583?helpref=related>] – Facebook, Does Facebook sell my information? Webpage



157	
158	
159	سلام خیلی خوشحالم ک این وقت شب برای ما شب بیدار ها فعال هستید، لطفا در صورت امکان شیرموز پسته شکر نداشته باشد بهتر است. دکتر کاظمی
160	
161	
162	
163	
164	

به‌روزرسانی ۲: توضیح کافه‌بازار در مورد آسیب‌پذیری امنیتی گزارش‌شده

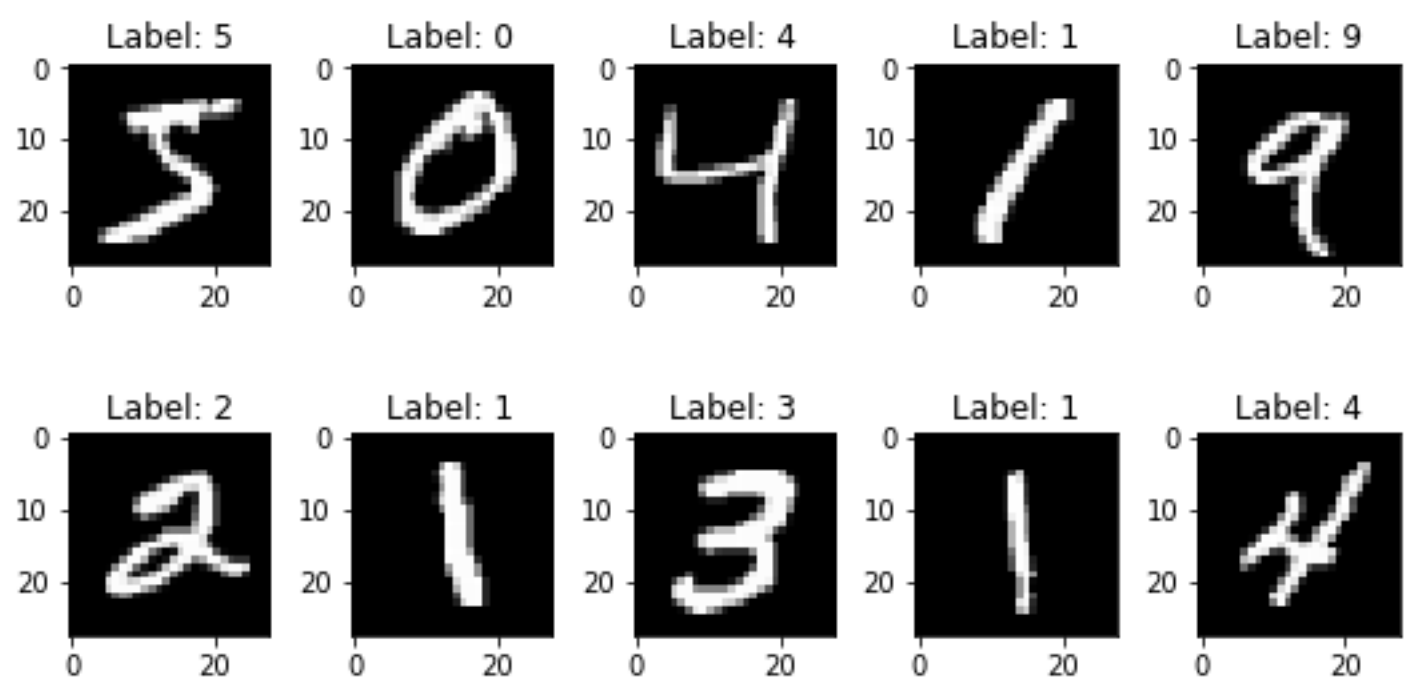
کافه‌بازار پیرو بیانیه‌ی قبلی و در راستای سیاست خود مبنی بر شفافیت، کاربران را در جریان جزئیات جدید نتایج بررسی‌های تیم فنی کافه‌بازار درباره‌ی گزارشی که صبح روز شنبه ۷ اردیبهشت در شبکه‌های اجتماعی انتشار یافت، قرار می‌دهد.

طبق بررسی‌های تیم فنی کافه‌بازار مشخص شده است که منبع‌کد یکی از زیرسیستم‌های وب‌سایت کافه‌بازار به دست افرادی خارج از مجموعه رسیده است؛ در عین حال، همچنان هیچ‌گونه شواهدی در زمینه نشت اطلاعات حساب‌های کاربری به دست نیامده است.

تیم فنی این مسئله را از ساعات ابتدایی روز شنبه با جدیت پیگیری کرد و اشکال امنیتی را شناسایی و برطرف کرد.

Academia Vs Industry

Data Type, Volume




```
.....
{
  "sort_timestamp": 1634275259292,
  "rating": 3.0,
  "helpful_votes": 0,
  "title": "Meh",
  "text": "These were lightweight and soft but much too small for my liking. I would have preferred two of these together to make one loc. For that reason I will not be repurchasing.",
  "images": [
    {
      "small_image_url": "https://m.media-amazon.com/images/I/81FN4c0VHzL._SL256_.jpg",
      "medium_image_url": "https://m.media-amazon.com/images/I/81FN4c0VHzL._SL800_.jpg",
      "large_image_url": "https://m.media-amazon.com/images/I/81FN4c0VHzL._SL1600_.jpg",
      "attachment_type": "IMAGE"
    }
  ],
  "asin": "B088SZDGXG",
  "verified_purchase": true,
  "parent_asin": "B08BBQ29N5",
  "user_id": "AEY0RY2AVMCPDV57CE337YU5LXA"
}
.....
```



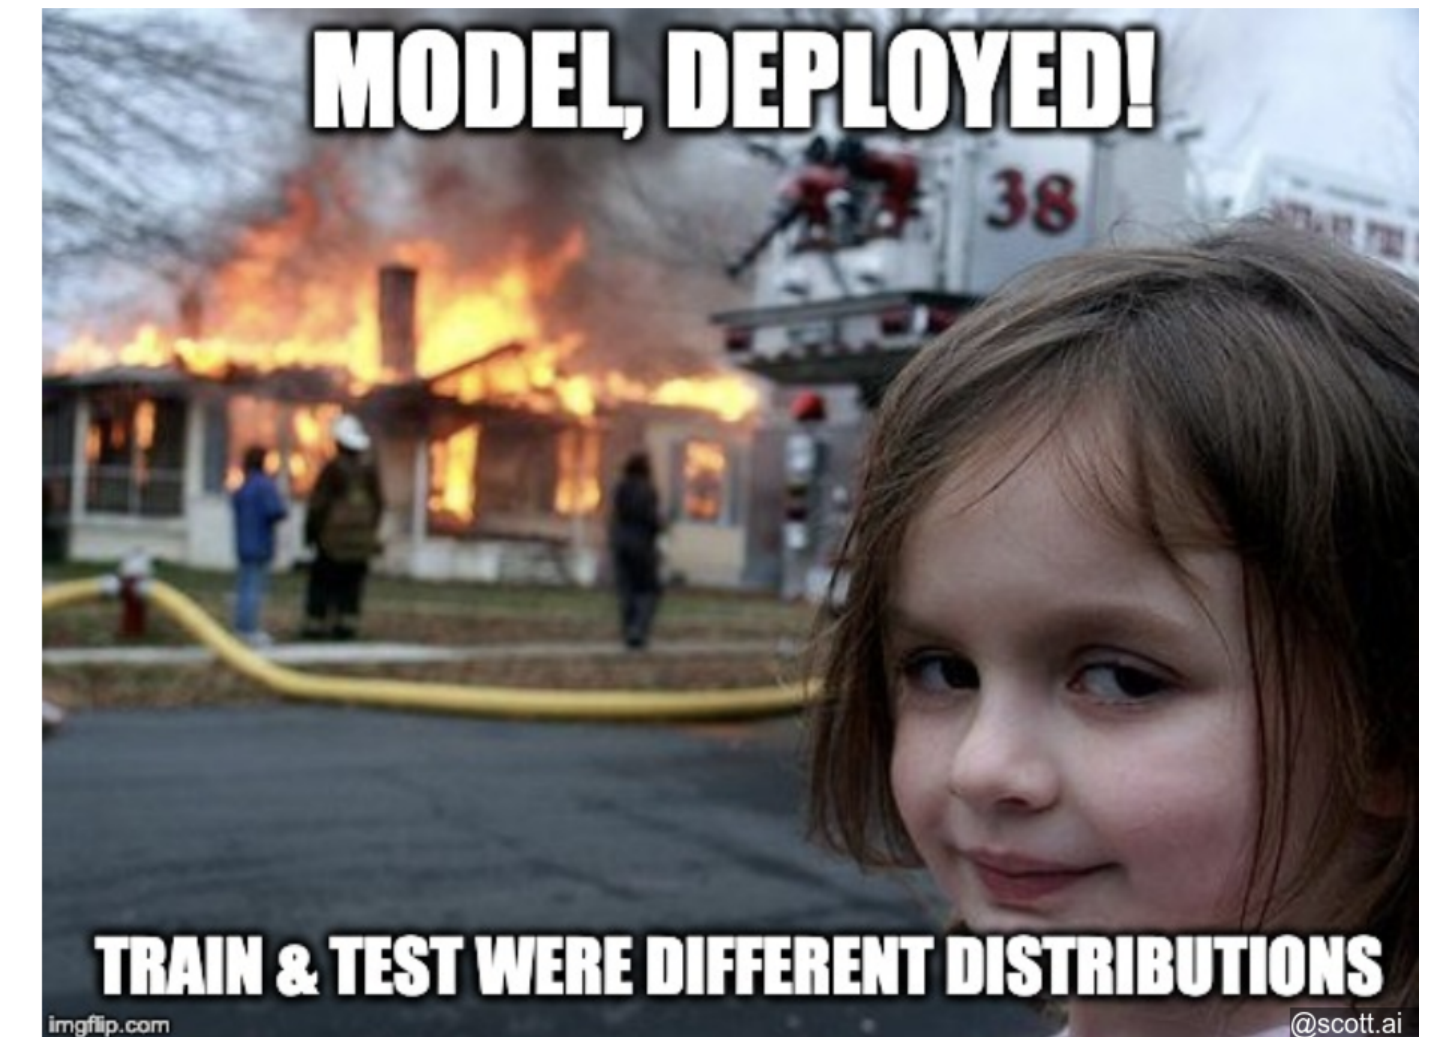
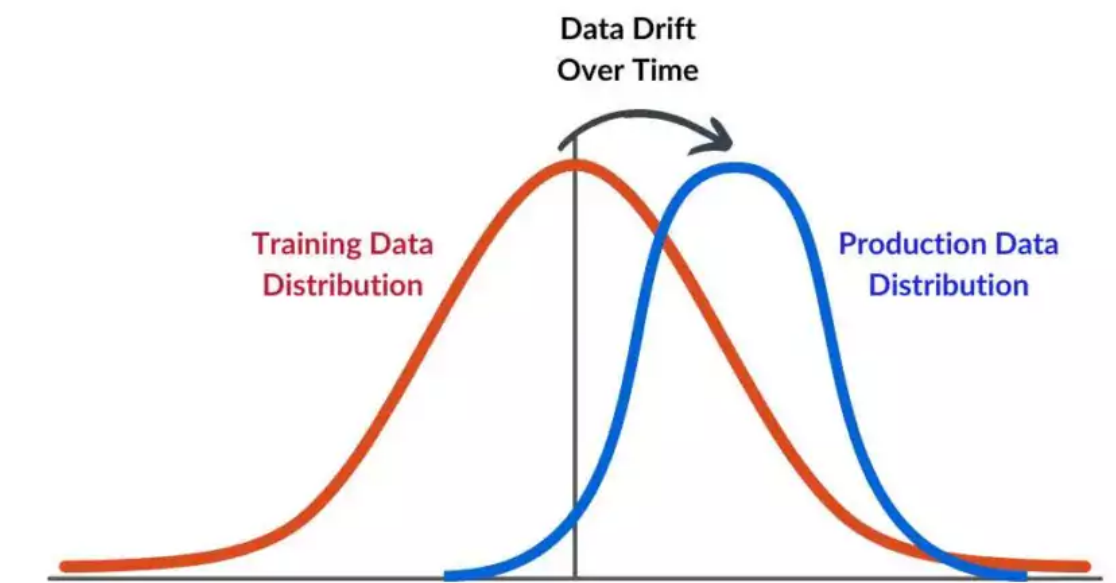

Academia Vs Industry

Data Quality

Handling Imbalanced Dataset in ML



statistics and
machine learning

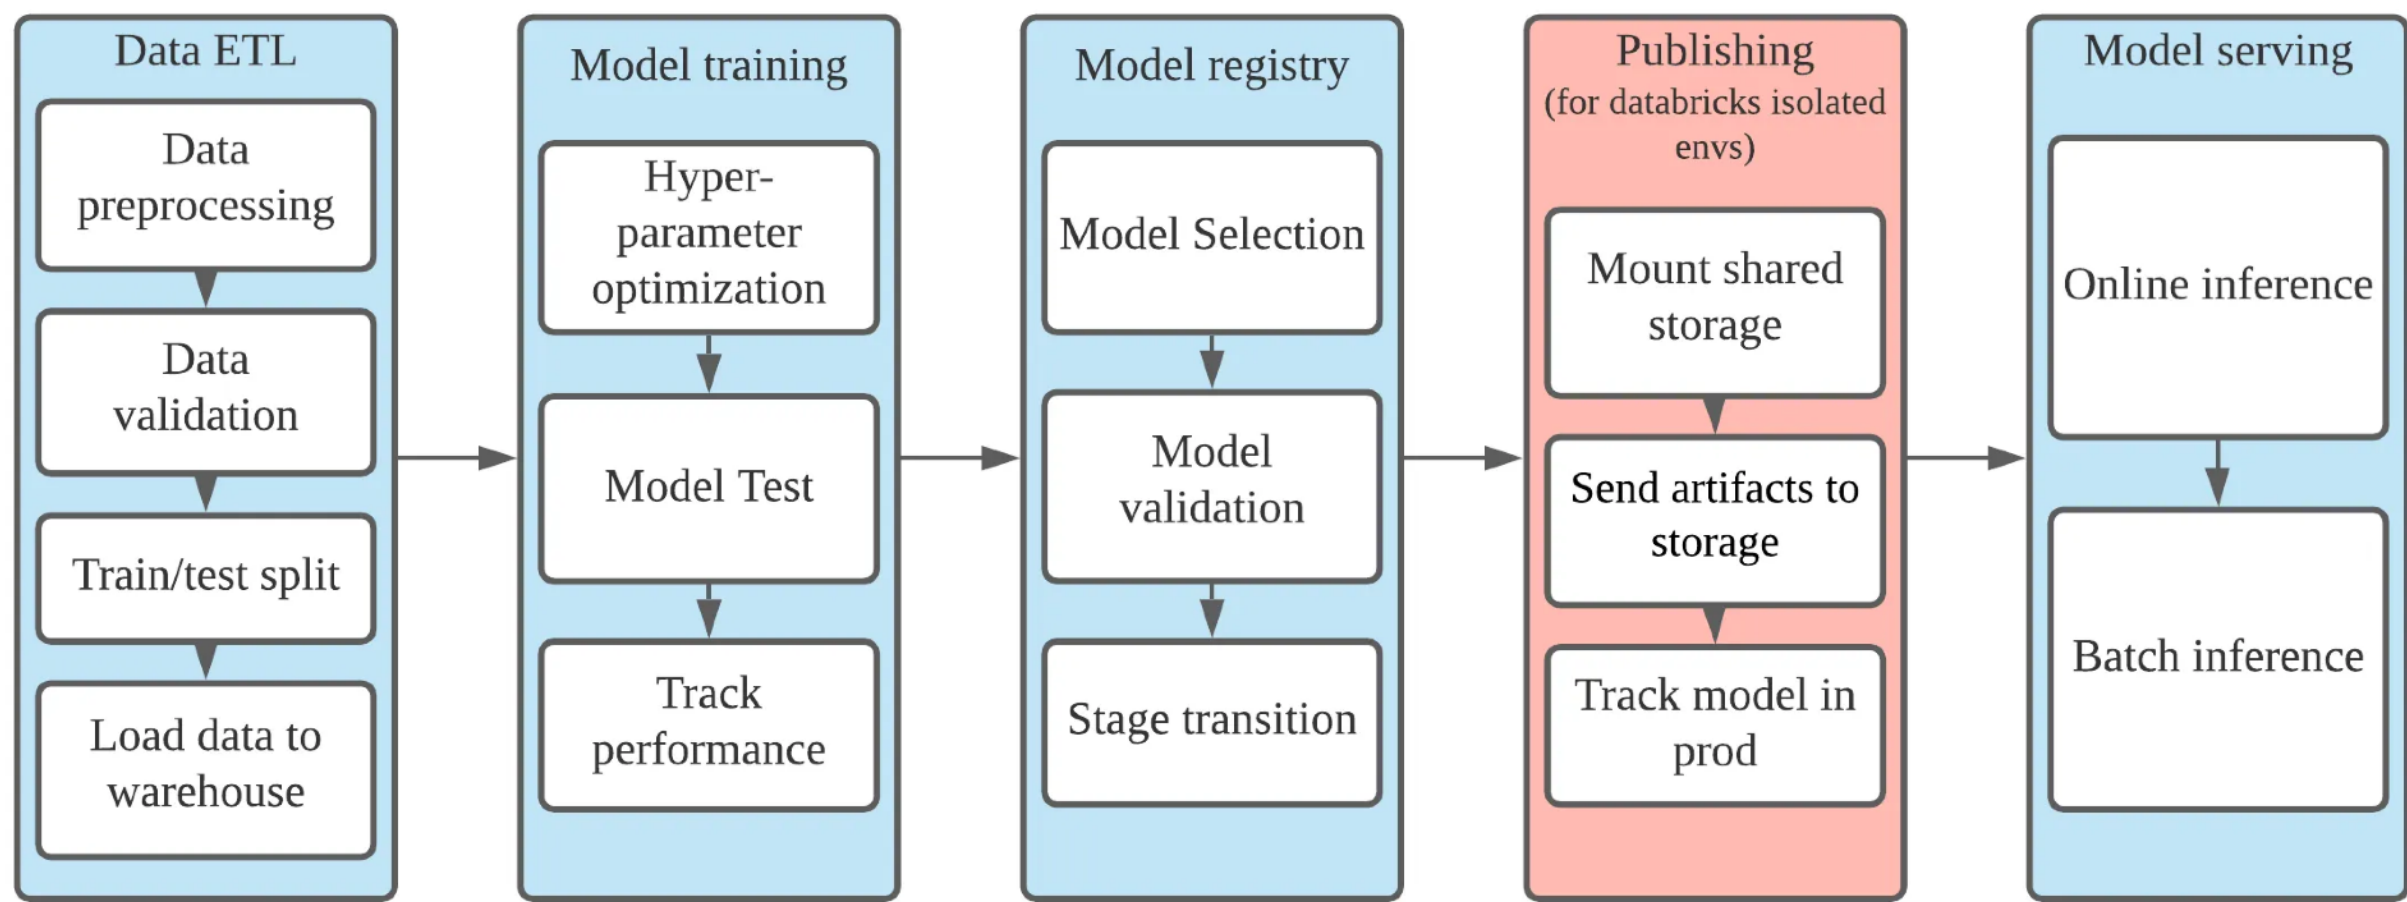


Academia Vs Industry

Infrastructure, Continuous Training

Some key facts about GPT-4:

- **Total parameters** — ~1.8 trillion (over 10x more than GPT-3)
- **Architecture** — Uses a mixture of experts (MoE) model to improve scalability
- **Training compute** — Trained on ~25,000 Nvidia A100 GPUs over 90-100 days
- **Training data** — Trained on a dataset of ~13 trillion tokens
- **Inference compute** — Runs on clusters of 128 A100 GPUs for efficient deployment
- **Context length** — Supports up to 32,000 tokens of context



Running Large Language Models (Llama 3) on Apple Silicon with Apple’s MLX Framework

Step-by-Step Guide to Implement LLMs like Llama 3 Using Apple’s MLX Framework on Apple Silicon (M1, M2, M3, M4)



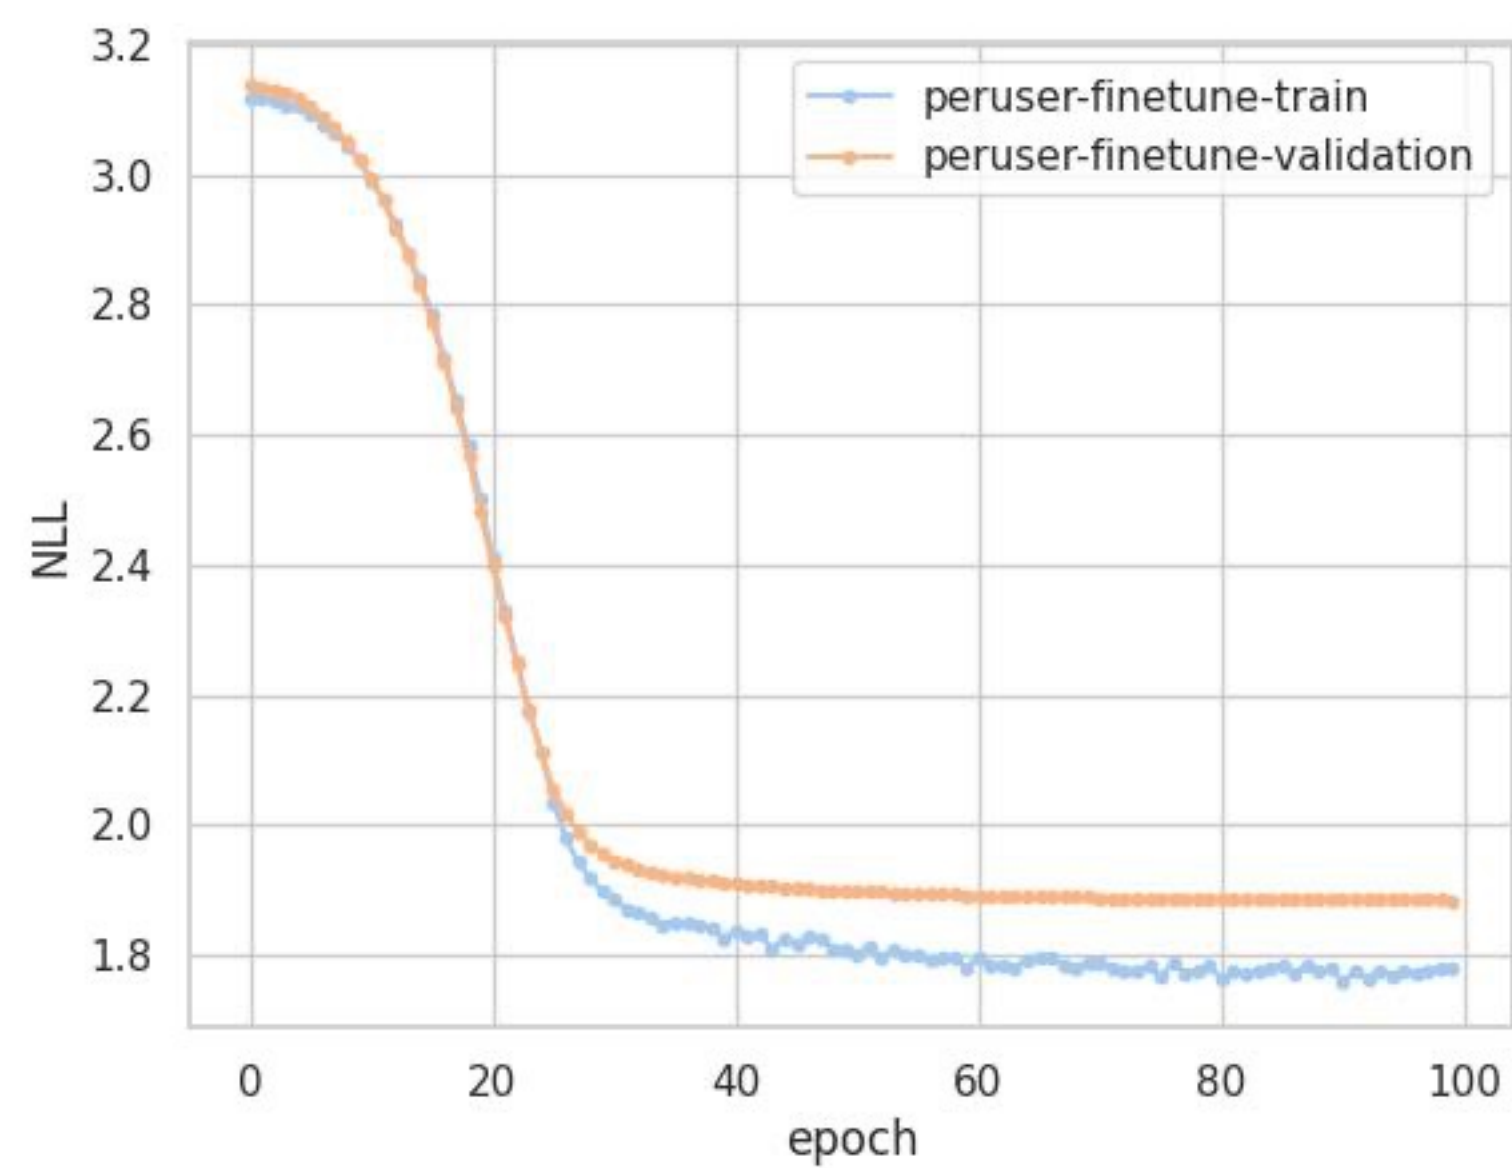
Manuel · [Follow](#)
5 min read · Jun 10, 2024



136

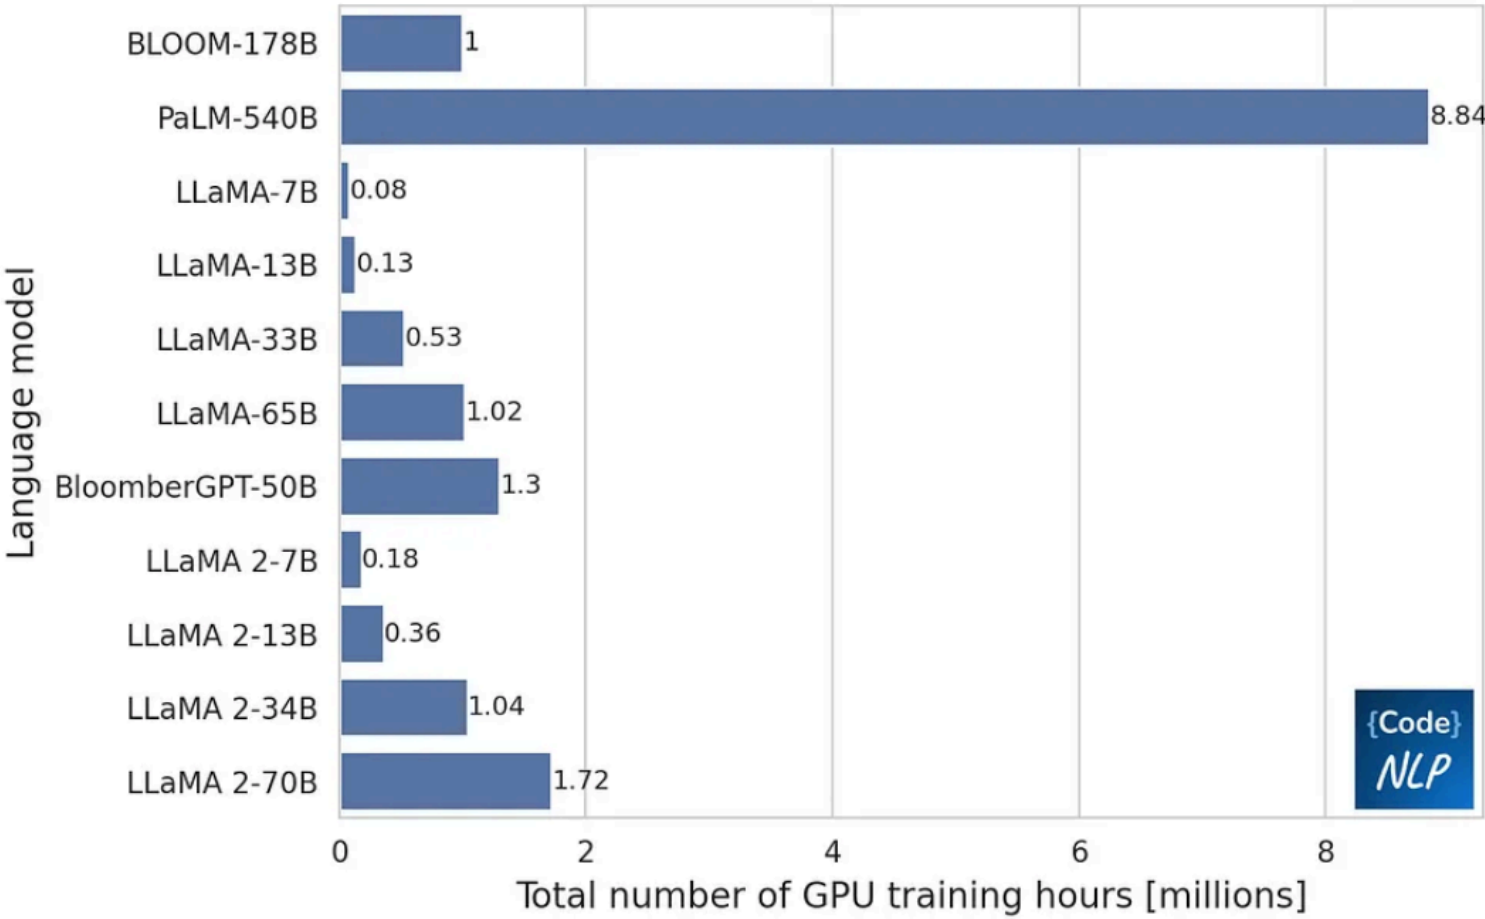
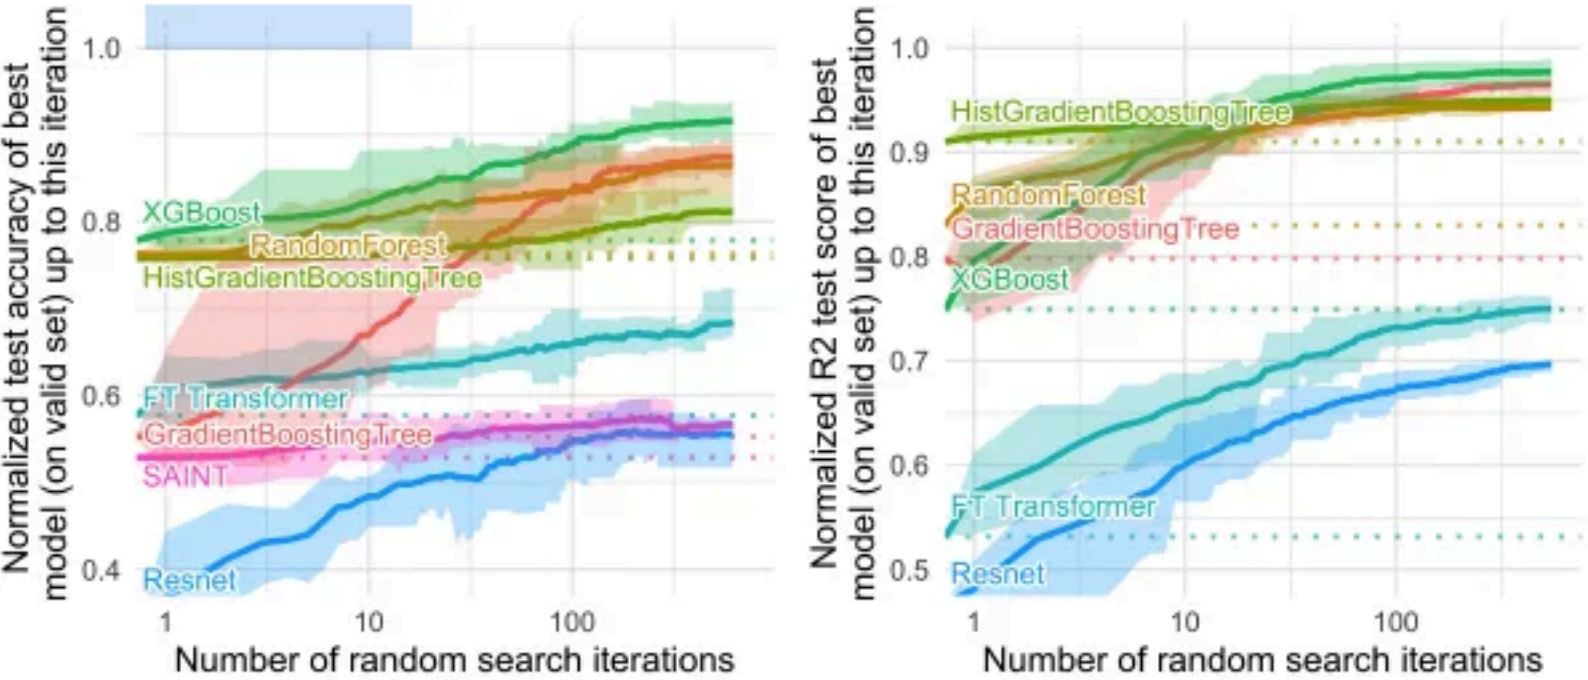



1



Academia Vs Industry

Solution Complexity



Model Name	Rossmann	CoverType	Higgs	Gas	Eye	Gesture
XGBoost	490.18 ± 1.19	3.13 ± 0.09	21.62 ± 0.33	2.18 ± 0.20	56.07 ± 0.65	80.64 ± 0.80
NODE	488.59 ± 1.24	4.15 ± 0.13	21.19 ± 0.69	2.17 ± 0.18	68.35 ± 0.66	92.12 ± 0.82
DNF-Net	503.83 ± 1.41	3.96 ± 0.11	23.68 ± 0.83	1.44 ± 0.09	68.38 ± 0.65	86.98 ± 0.74
TabNet	485.12 ± 1.93	3.01 ± 0.08	21.14 ± 0.20	1.92 ± 0.14	67.13 ± 0.69	96.42 ± 0.87
1D-CNN	493.81 ± 2.23	3.51 ± 0.13	22.33 ± 0.73	1.79 ± 0.19	67.9 ± 0.64	97.89 ± 0.82
Simple Ensemble	488.57 ± 2.14	3.19 ± 0.18	22.46 ± 0.38	2.36 ± 0.13	58.72 ± 0.67	89.45 ± 0.89
Deep Ensemble w/o XGBoost	489.94 ± 2.09	3.52 ± 0.10	22.41 ± 0.54	1.98 ± 0.13	69.28 ± 0.62	93.50 ± 0.75
Deep Ensemble w XGBoost	485.33 ± 1.29	2.99 ± 0.08	22.34 ± 0.81	1.69 ± 0.10	59.43 ± 0.60	78.93 ± 0.73


Each column is a dataset. Better performances are highlighted with bold numbers.

Model Name	YearPrediction	MSLR	Epsilon	Shrutime	Blastchar
XGBoost	77.98 ± 0.11	55.43 ± 2e-2	11.12 ± 3e-2	13.82 ± 0.19	20.39 ± 0.21
NODE	76.39 ± 0.13	55.72 ± 3e-2	10.39 ± 1e-2	14.61 ± 0.10	21.40 ± 0.25
DNF-Net	81.21 ± 0.18	56.83 ± 3e-2	12.23 ± 4e-2	16.8 ± 0.09	27.91 ± 0.17
TabNet	83.19 ± 0.19	56.04 ± 1e-2	11.92 ± 3e-2	14.94 ± 0.13	23.72 ± 0.19
1D-CNN	78.94 ± 0.14	55.97 ± 4e-2	11.08 ± 6e-2	15.31 ± 0.16	24.68 ± 0.22
Simple Ensemble	78.01 ± 0.17	55.46 ± 4e-2	11.07 ± 4e-2	13.61 ± 0.14	21.18 ± 0.17
Deep Ensemble w/o XGBoost	78.99 ± 0.11	55.59 ± 3e-2	10.95 ± 1e-2	14.69 ± 0.11	24.25 ± 0.22
Deep Ensemble w XGBoost	76.19 ± 0.21	55.38 ± 1e-2	11.18 ± 1e-2	13.10 ± 0.15	20.18 ± 0.16

Each column is a dataset. Better performances are highlighted with bold numbers.

Academia Vs Industry

Evaluation Metrics



Doubly Robust

- Estimating ATE with Doubly Robust estimator:

$$ATE_{DR} = \frac{1}{n} \sum_{i=1}^n \left[\frac{T_i Y_i}{\hat{e}(X_i)} - \frac{\{T_i - \hat{e}(X_i)\}}{\hat{e}(X_i)} \hat{m}_1(X_i) \right] - \frac{1}{n} \sum_{i=1}^n \left[\frac{(1 - T_i) Y_i}{1 - \hat{e}(X_i)} + \frac{\{T_i - \hat{e}(X_i)\}}{1 - \hat{e}(X_i)} \hat{m}_0(X_i) \right]$$

- Unbiased* if either **propensity score** or **regression** model is correct
- This property is referred to as *double robustness*

$$m_0 = E(Y|T = 0, X)$$

$$m_1 = E(Y|T = 1, X)$$

		Predicted values		
		True	False	
Actual	True	True Positive (TP)	False Negative (FN) Type 1 Error	Recall = Sensitivity = $\frac{TP}{TP + FN}$
	False	False Positive (FP) Type 1 Error	True Negative (TN)	Specificity = $\frac{TN}{TN + FP}$
		Precision = $\frac{TP}{TP + FP}$		Accuracy = $\frac{TP + TN}{TP + TN + FP + FN}$ $F1 = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$

B. Classification Model Results

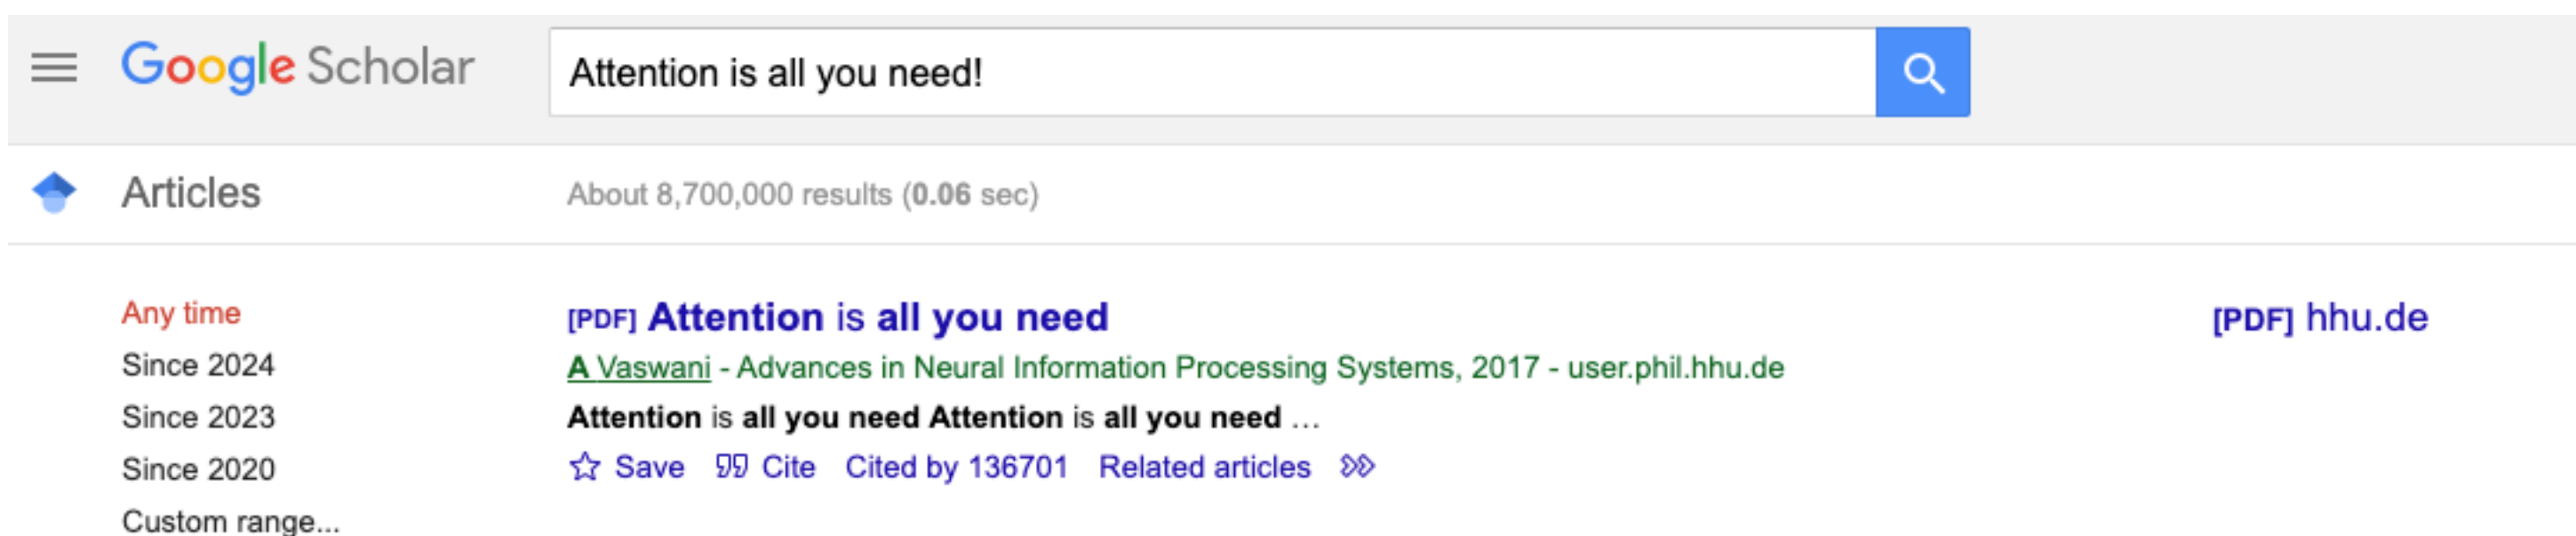
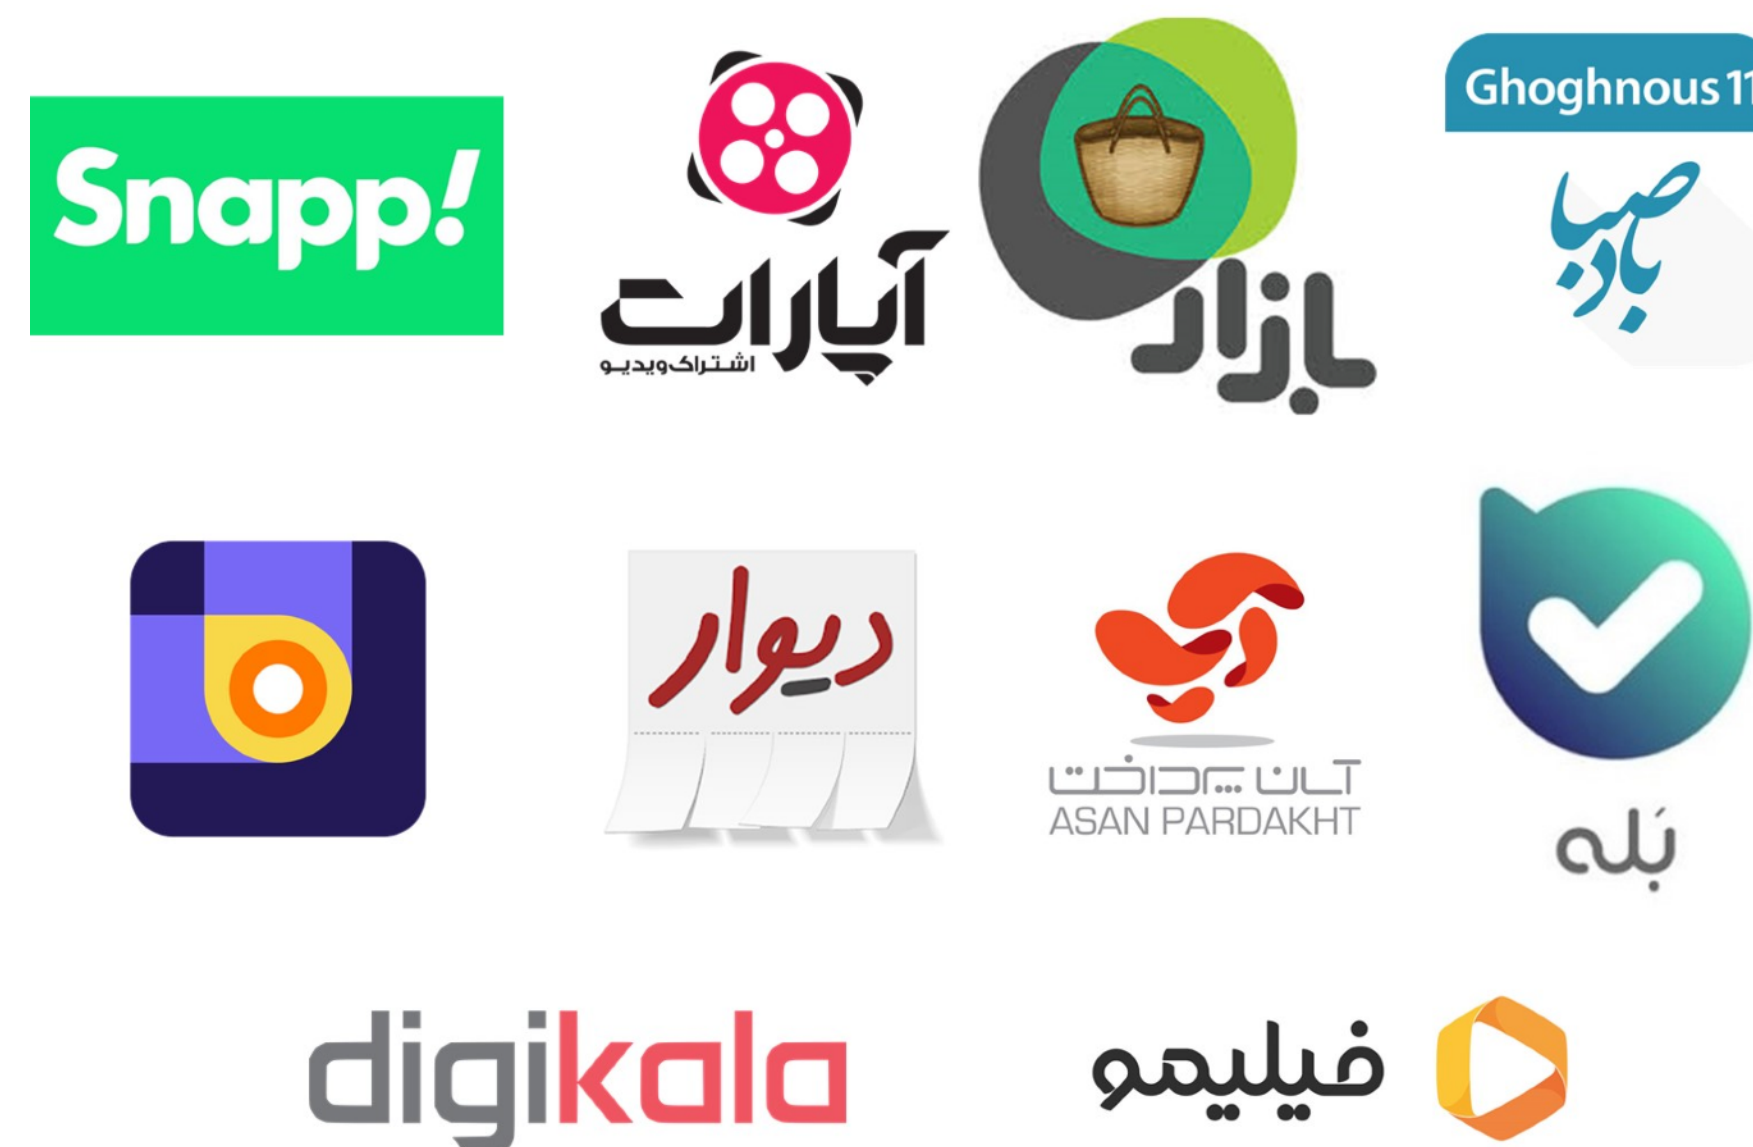


Academia Vs Industry

Values, Blue or Red pill

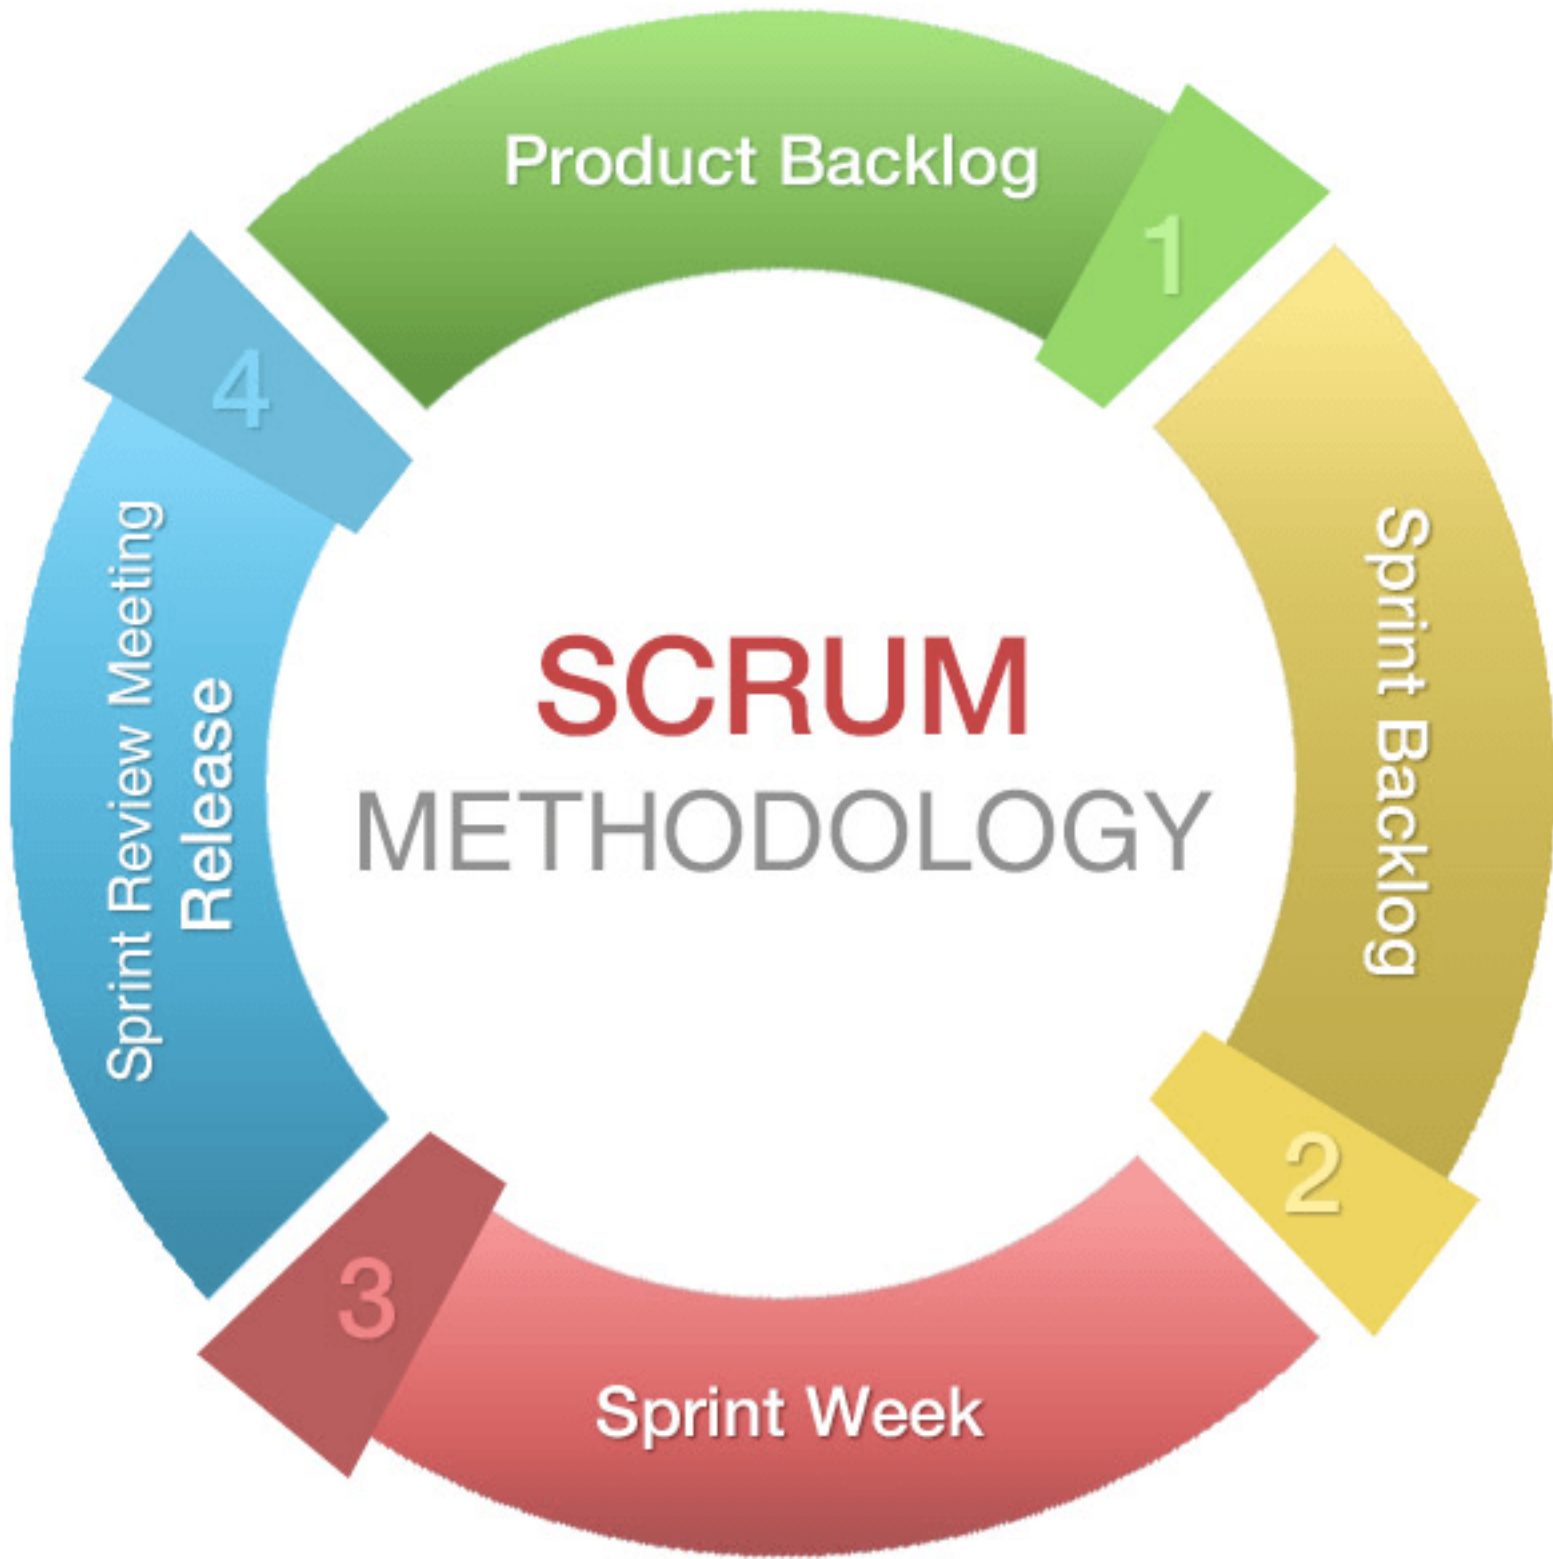




The Choice is Yours!



Academia Vs Industry

Project Management



Scrum and Machine Learning

Positions

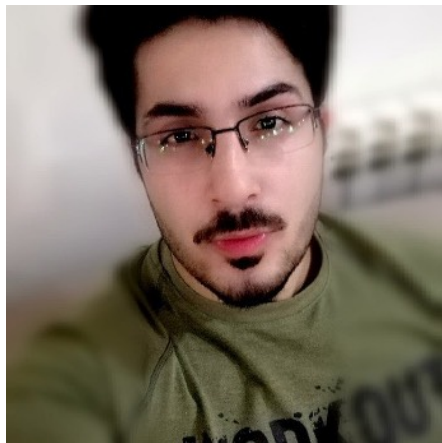
Machine Learning Roles



Machine Learning



Data Scientist




ML Engineer



Data Engineer



Infrastructure



Business



Data Analyst

Scrum and ML

Product Manager is Super Important


- **View ML system as product is HARD.**
- Maintaining Backlog is a Job.
- Finding Business Opportunities.
- Academic People do not pay attention to business.
- Intra-team Communications.
- Ego in academic people.
- ***Technical Product Manager (TPM).***



Scrum and ML

Standup Meetings

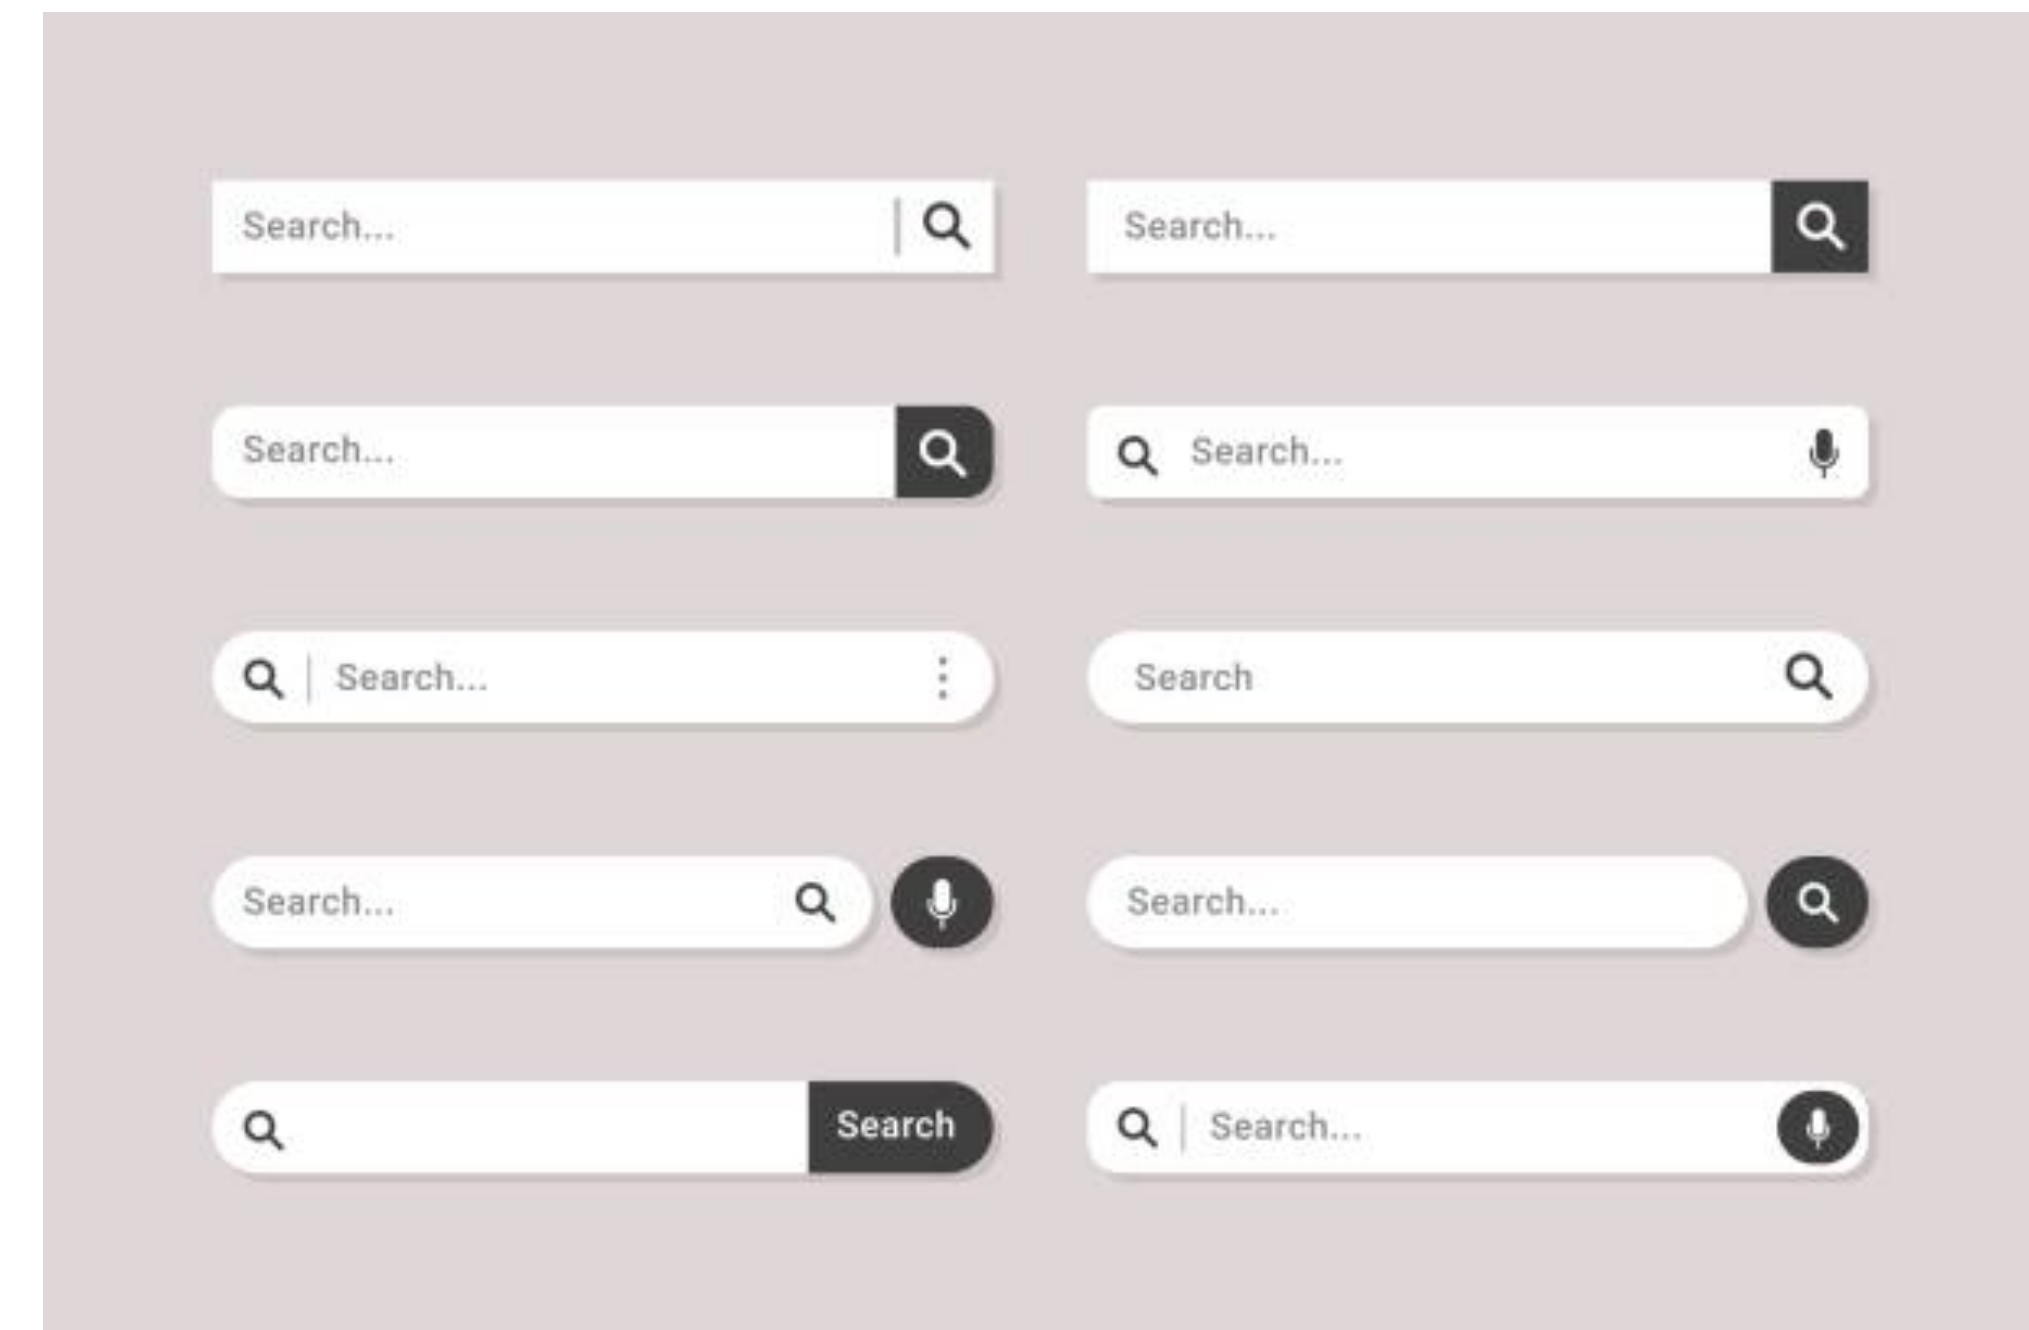
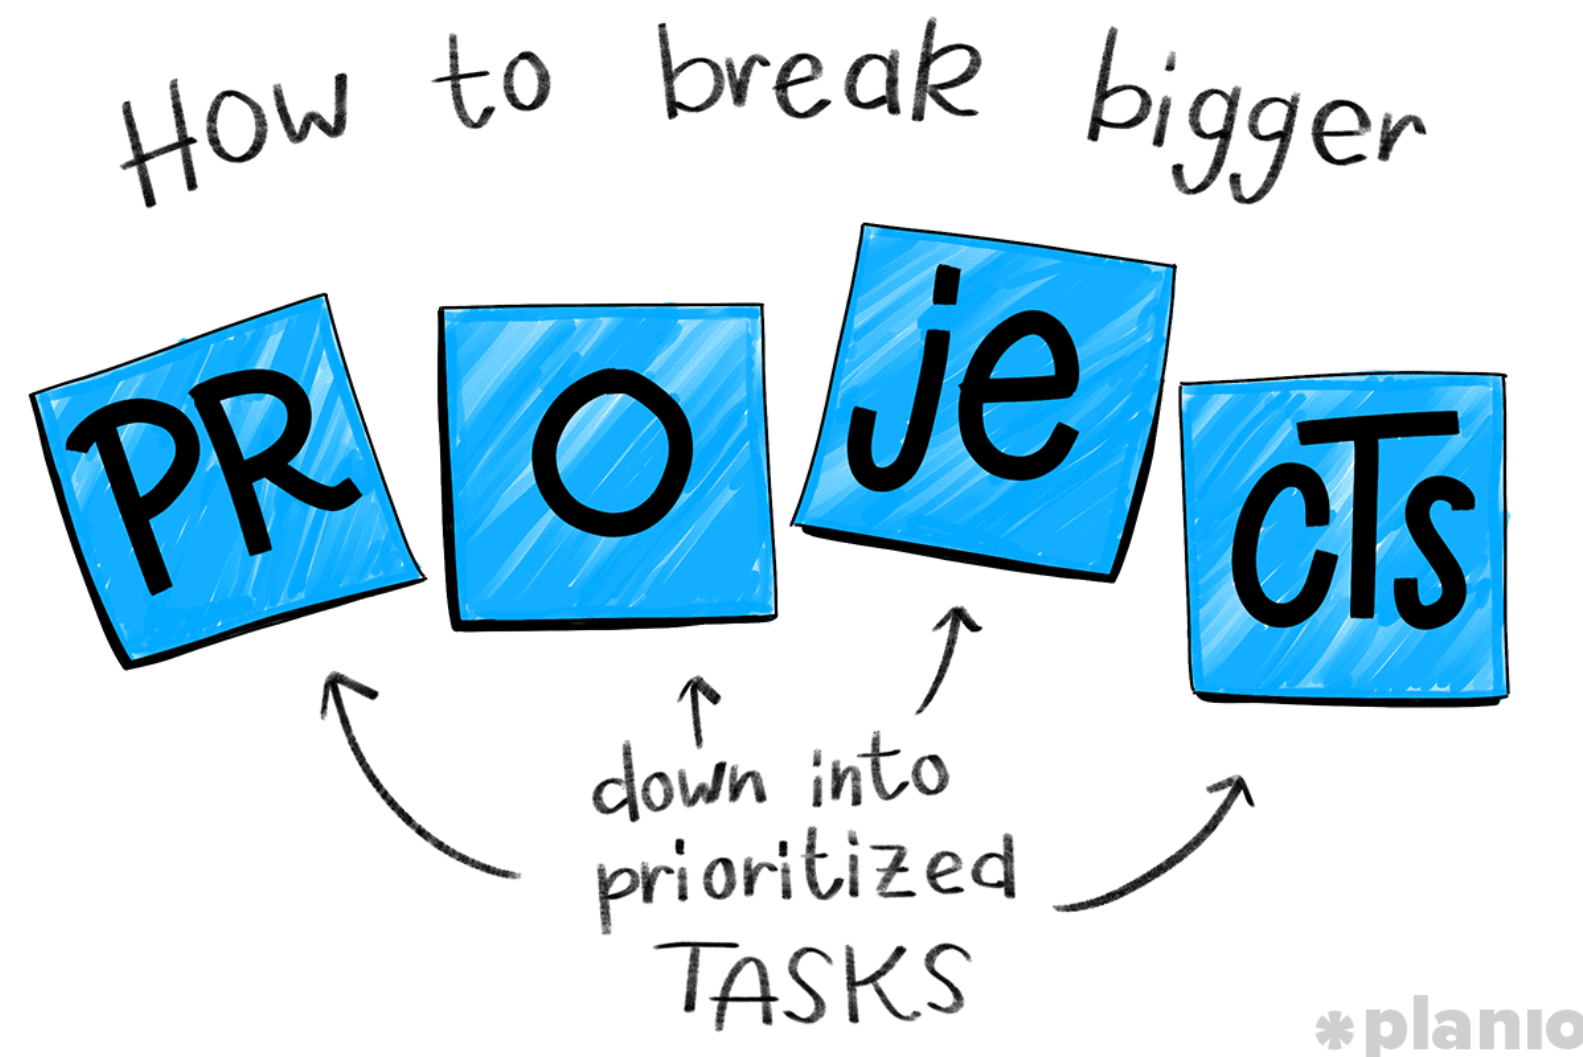

- **Sense of Progress.**
- **Fail-fast Mindset.**
- **Pickup fights.**
- **Speed Control.**
- **Inter-team speed difference.**
- **Irrelevant tasks Issue.**
- **Means Start of The Day.**
- **Easily Could Break the Time Box.**



Scrum and ML

Refinement / Vague Backlog

- Define DoDs are challenging in ML Systems.
- Time Boxing Issues. (EDA, Increasing performance x%, debugging, ...)
- Data Driven Scrum Insights.



Scrum and ML

Refinement


- **Curse of Brilliant People.**
- **Performance Monitoring.**
- **Maintenance.**
- **POC in machine learning.**
- **Double checking core idea/implementation.**
- **Novel things estimation?**
- **It's enough.**
- **Consider Buffer.**



Scrum and ML

Review


- Evaluation Metric of Sprint.
- You fire some one here.
- Excuses emerge here.
- Be strict on DoDs.



Scrum and ML

Retro

- If you do not seek team's progress:
 - Go to therapy.
 - Leave.
- Successful Stories.





How to Success

As a Data Scientist

- Learn fundamentals by your heart.
- Intuitively know what you do.
- Blend in teams.
- Not too aggressive, Not a potato.
- Be ambitious.
- Be Multi-Dimensional.
- **Work Ethics.**



You should become Gholamreza in your field



ANY QUESTIONS?

IF NOT, JUST CLAP

makeameme.org