



Universitat
Pompeu Fabra
Barcelona

Hidden Persuasion: Detecting Manipulative Narratives on Social Media During the 2022 Russian Invasion of Ukraine

Kateryna Akhynko
Ukrainian Catholic University


Oleksandr Kosovan
Ukrainian Catholic University

Mykola Trokhymovych
Pompeu Fabra University


Background

73% of Ukrainians use Telegram as a primary source of information
(USAID-Internews, summer, 2024):

Користування соціальними мережами для спілкування, 2023-2024



Переважна мережа для отримання новин в соціальних мережах, 2023-2024



■ 2024 ■ 2023

Background

*Are we reading facts
or interpretations disguised
as facts?*

! путін грає з вогнем: він не розуміє, що якби не я, з росією вже сталося б багато дуже поганих речей, і я маю на увазі ДУЖЕ поганих, – Трамп.

Риторика Президента США змінюється останніми днями, побачимо, чи зміниться щось у діях👁️👁️

Як це вплине на ситуацію в Україні?



7,4K



5K



1,9K



487



409



236



209



83

👁️ 831,4K edited 11:45

Background

*Are we reading facts
or interpretations disguised
as facts?*

bolded text

**side comments
by unknown author**

emojii



путін грає з вогнем: він не розуміє,
що якби не я, з росією вже сталося б
багато дуже поганих речей, і я маю на
увазі ДУЖЕ поганих, – Трамп.

Риторика Президента США змінюється
останніми днями, побачимо, чи зміниться
щось у діях



another
emojii

Як це вплине на ситуацію в Україні?



7,4K



5K



1,9K



487



409



236



209



83



831,4K

edited 11:45

>800k people viewed the post

Background

*Are we reading facts
or interpretations disguised
as facts?*

Вениславский: 99% ограниченно пригодных мужчин после прохождения повторной ВЛК признаются пригодными к военной службе.

Вот что медицина украинская делает.

😊 11,6K

🤡 4,2K

🐒 1,7K

😱 553

❤️ 306

🔥 174

💰 129

🐳 119

🏆 110

👉 74

🕊️ 56

👁️ 1M 12:45

Background

*Are we reading facts
or interpretations disguised
as facts?*

bolded text

**side comments
by unknown author**

Вениславский: 99% ограниченно пригодных мужчин после прохождения повторной ВЛК признаются пригодными к военной службе.

Вот что медицина украинская делает.

😊 11,6K

🤡 4,2K

🐒 1,7K

😱 553

❤️ 306

🔥 174

💰 129

🐳 119

🏆 110

👉 74

🕊️ 56

👁️ 1M 12:45

**1 million people
viewed the post**

Problem formulation

Goal:

Detect **manipulative narratives** in Ukrainian Telegram posts.

Manipulation defined (UNLP 2025):

The **use of rhetorical or stylistic techniques** to influence readers' opinions or behavior — **without relying on factual evidence**.

Problem formulation

Tasks

Telegram Message

Недільний ранок у Ростові не виявився скучним. Хвалене
рашистське ппо пробувало збити якийсь безпілотник. І в той самий
час був перекритий рух по керчинському мосту. А що сі стало?

Technique Classification

loaded language

euphoria

cliche

Span Identification

Недільний ранок у Ростові **не виявився скучним. Хвалене**
рашистське ппо пробувало збити якийсь безпілотник. І в той самий
час був перекритий рух по керчинському мосту. А **що сі стало?**

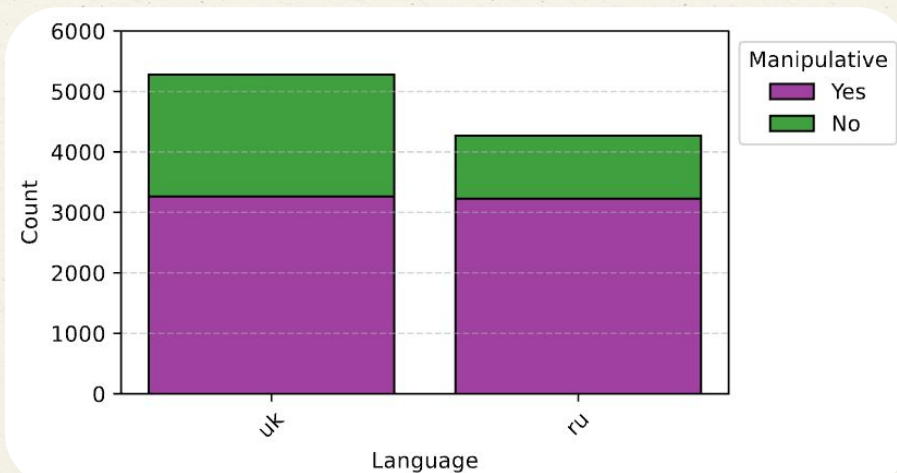
Data Overview

- Source: [Telegram](#) posts from Ukrainian channels (provided by UNLP 2025 Shared Task)
- Each post is annotated with **manipulation techniques** and **manipulative spans**

- 2 [languages](#) present:

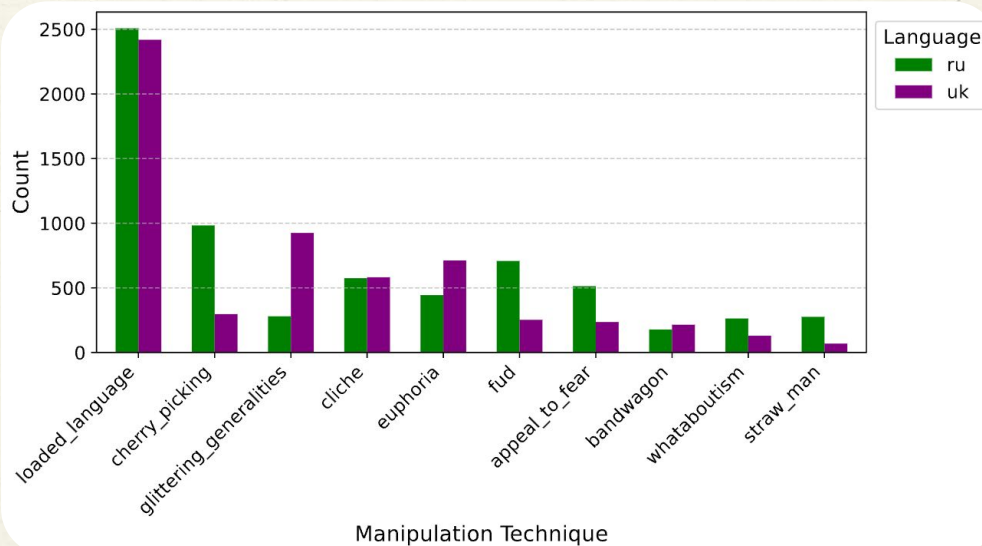
Ukrainian: 5,278 posts

Russian: 4,269 posts

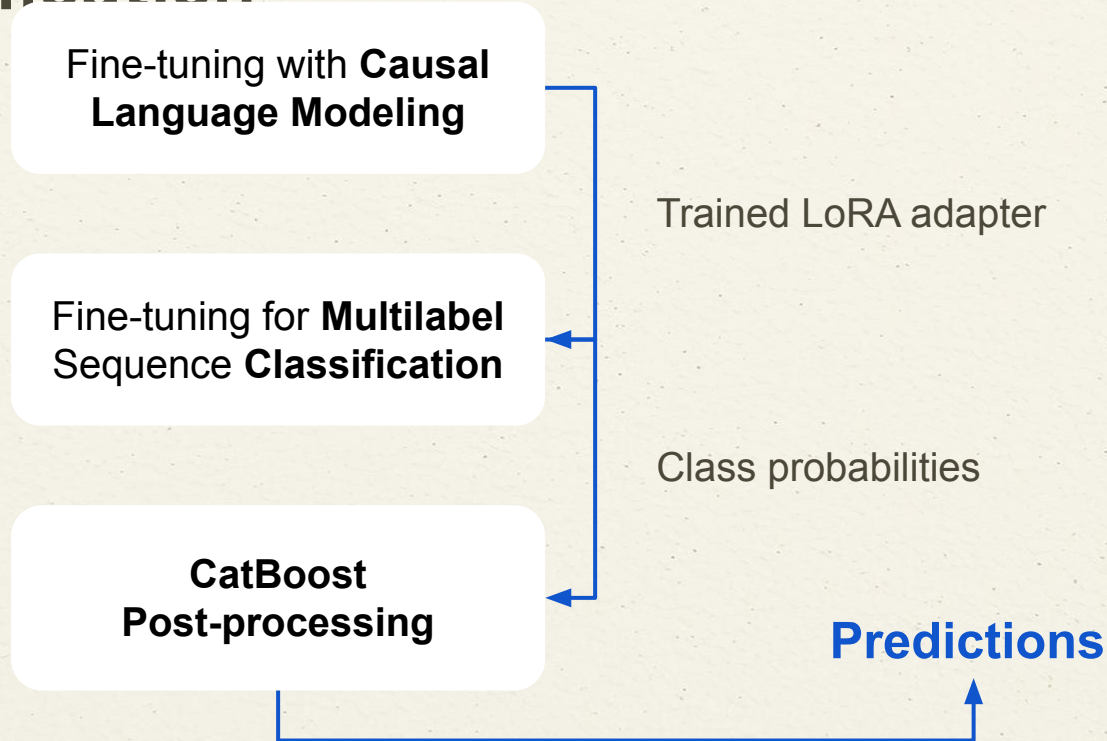


Data Overview

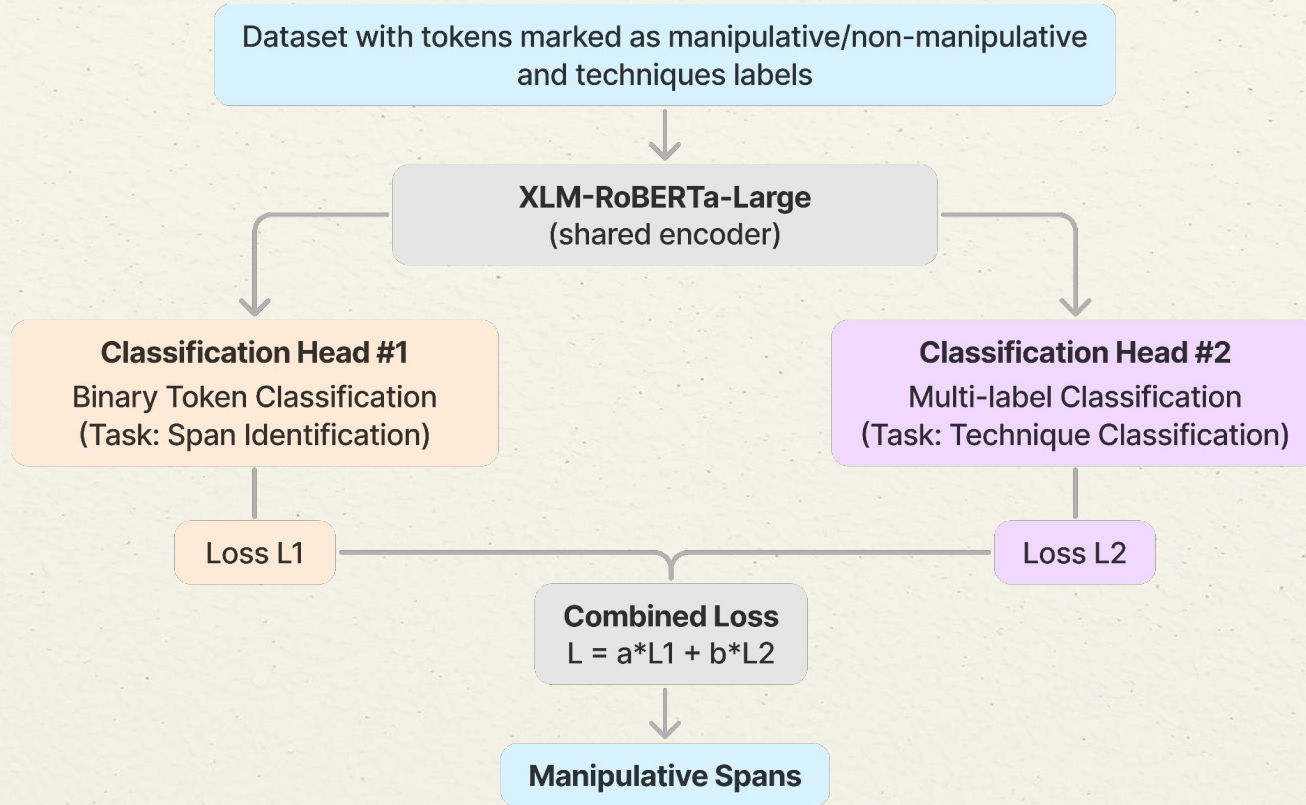
- Source: [Telegram](#) posts from Ukrainian channels (*provided by UNLP 2025 Shared Task*)
- Each post is annotated with **manipulation techniques** and **manipulative spans**
- 10 predefined **techniques**:



Proposed Solution – Technique Classification



Proposed Solution for Span Identification



Results

Metrics

```
graph TD; Metrics[Metrics] --> TC[Technique Classification]; Metrics --> SI[Span Identification]; TC --- TC_Metric[macro-averaged F1 score]; SI --- SI_Metric[span-level F1-score];
```

Technique Classification

macro-averaged F1 score

Span Identification

span-level F1-score

Results – Technique Classification

Team	Public	Private
GA	0.47369	0.49439
MolodiAmbitni (Gemma2 w/PP)	0.46203	0.46952
MolodiAmbitni (Gemma2)	0.43933	0.45543
CVisBetter_SEU	0.43669	0.45519

Comparison of metrics for top-3 solutions from competition leaderboard

Results – Technique Classification

Technique	F1 score	Support
loaded_language	0.782	2959
glittering_generalities	0.644	723
euphoria	0.550	695
fud	0.525	576
cherry_picking	0.467	768
appeal_to_fear	0.450	449
cliche	0.328	695
whataboutism	0.296	235
straw_man	0.287	207
bandwagon	0.215	236

Results – Span Identification

Solution	Public	Private
GA	0.64598	0.64058
CVisBetter_SEU	0.59873	0.60456
MolodiAmbitni	0.59662	0.60001
OpenBabylon	0.59142	0.59096
MolodiAmbitni (baseline)	0.58617	0.58794

Comparison of metrics for top-4 solutions from competition leaderboard

Conclusions

- Achieved **2nd place** in **technique classification** and **3rd place** in **span detection** in the UNLP 2025 Shared Task
- Developed fine-tuned Gemma 2 + meta-feature post-processing that **significantly boosted** classification performance
- Showed that a simple **XLM-RoBERTa model**, paired with a **dual-head pipeline**, can achieve **top-tier** span detection **results**

Thank you!

Q&A

Stage 1: Fine-tuning with CLM

Model

Gemma 2B IT



Training Setup

LoRA (Alpha (α): 32,
Rank (r): 32)
+ 4-bit quantization

in causal LM setup

Output

LoRA adapter for
techniques
generation

Stage 1: Fine-tuning with CLM

Prompt Composition

System:

You are an AI trained to detect rhetorical manipulation in social media. Return ONLY the technique names from the list, comma-separated.

User:

***Task:** Identify techniques in this post using ONLY the following: <techniques description>*

***Examples:** <2 examples of posts + their techniques>*

***POST to analyze:** <target post text>*

Assistant:

Predicted output: <technique1, technique2, ...>

Stage 2: Supervised Multi-label Classification

Model: Gemma 2B IT + LoRA adapter from Stage 1

Training Setup:

1. Multi-label sequence classification
2. LoRA (Alpha (α): 32, Rank (r): 16) adapter
3. Threshold selection per class

Output: class probabilities for each text

Stage 3: Post-Processing

Model Used: CatBoost

Features Used:

- technique probabilities from Stage 2
- cosine distances -> current **text** and **centroids** of trigger phrase clusters
- **frequency** of techniques among top-20 **nearest texts** and **trigger phrases**
- meta-features :
word count, number of question marks, presence of URLs, etc