



# Revision quality algorithms: a subjective view

Strainu ([wiki@strainu.ro](mailto:wiki@strainu.ro))

**WIKIMANIA**  
**KATOWICE**




WIKIMANIA  
KATOWICE



WIKIMANIA  
KATOWICE






WIKIMANIA  
KATOWICE

# Should I use Automoderator?

WIKIMANIA  
KATOWICE



**Should I use  
Automoderator?**

**YES!**

**WIKIMANIA  
KATOWICE**



# Should I use Automoderator?

**YES!**

(unless you have a better option...)

**WIKIMANIA  
KATOWICE**





# Revision... what?

**WIKIMANIA**  
**KATOWICE**





# Some keywords...

- ❖ ORES
- ❖ Revision scoring
- ❖ Revert risk
- ❖ Automoderator
- ❖ ClueBot

**WIKIMANIA**  
**KATOWICE**



# Automatic reverts! (AR)

**WIKIMANIA**  
**KATOWICE**



# How do AR work?

30 iulie 2024

► Lista abrevierilor:

- o (dif | ist) . . **m!** Half-Life: Opposing Force; 14:58 . . (+3) . . **761edxwrd** (discuție | contribuții | blocare) (Etichetă: Editare vizuală) (revenire | mulțumesc)
- o (dif | ist) . . **m!** Half-Life: Opposing Force; 14:58 . . (+1) . . **761edxwrd** (discuție | contribuții | blocare) (Etichetă: Editare vizuală) (mulțumesc)
- o (dif | ist) . . **m** Categorie:Mișcare; 14:56 . . (+30) . . GEO (discuție | contribuții | blocare) (*adăugat Categorie:Fenomene fizice via HotCat*) (revenire | mulțumesc)
- o (dif | ist) . . **m!** Half-Life: Opposing Force; 14:55 . . (-8) . . **761edxwrd** (discuție | contribuții | blocare) (→*Sharpe*) (Etichetă: Editare vizuală) (mulțumesc)
- o (dif | ist) . . Categorie:Mișcări; 14:55 . . (+71) . . GEO (discuție | contribuții | blocare) (*{{Distinge|Categorie:Mișcare}}*) (revenire | mulțumesc)
- o (dif | ist) . . **!** Half-Life: Opposing Force; 14:54 . . (+3.094) . . **761edxwrd** (discuție | contribuții | blocare) (*Adăugare de informații suplimentare*) (Etichetă: Editare vizuală) (mulțumesc)
- o (dif | ist) . . **N** Categorie:Mișcări artistice în Asia; 14:54 . . (+137) . . Flondin (discuție | contribuții | blocare) (*categorie nouă*) (mulțumesc)
- o (dif | ist) . . **!** Limbaj natural; 14:53 . . (+26) . . 178.138.98.136 **!** (discuție | blocare) (→*Vezi și: realism first*) (revenire)
- o (dif | ist) . . Péter Magyar; 14:52 . . (+11) . . Andrei Stroe (discuție | contribuții | blocare) (revenire | mulțumesc)
- o (dif | ist) . . Categorie:Mișcare; 14:48 . . (+87) . . GEO (discuție | contribuții | blocare) (*{{Distinge|Categorie:Mișcări}}*) (mulțumesc)
- o (dif | ist) . . Mstislav Dobujinski; 14:46 . . (+432) . . Flondin (discuție | contribuții | blocare) (*completare*) (Etichetă: Legături către dezambiguizare) (revenire | mulțumesc)
- o (dif | ist) . . **!** Realism (filozofie); 14:43 . . (-2) . . 178.138.98.136 **!** (discuție | blocare) (*plural*) (revenire)
- o (dif | ist) . . **!** Discuție:Norman Manea; 14:41 . . (+309) . . 178.138.98.136 **!** (discuție | blocare) (→*Paragraf în articol: pasaj extras, urmat de*) (revenire)
- o (dif | ist) . . Mstislav Dobujinski; 14:38 . . (+206) . . Flondin (discuție | contribuții | blocare) (*completare*) (mulțumesc)

**WIKIMANIA**  
**KATOWICE**



# How do AR work?

30 iulie 2024

► Lista abrevierilor:

- (dif | ist) . . ! Inteligență artificială; 15:05 . . (+42) . . 178.138.98.136 ⓘ (discuție | blocare) (→*Vezi și: nu*) (revenire)
- (dif | ist) . . m! Half-Life: Opposing Force; 14:58 . . (+3) . . 761edxwrd (discuție | contribuții | blocare) (Etichetă: Editare vizuală) (revenire | mulțumesc)
- (dif | ist) . . m! Half-Life: Opposing Force; 14:58 . . (+1) . . 761edxwrd (discuție | contribuții | blocare) (Etichetă: Editare vizuală) (mulțumesc)
- (dif | ist) . . m! Half-Life: Opposing Force; 14:55 . . (-8) . . 761edxwrd (discuție | contribuții | blocare) (→*Sharpe*) (Etichetă: Editare vizuală) (mulțumesc)
- (dif | ist) . . ! Half-Life: Opposing Force; 14:54 . . (+3.094) . . 761edxwrd (discuție | contribuții | blocare) (*Adăugare de informații suplimentare*) (Etichetă: Editare vizuală) (mulțumesc)
- (dif | ist) . . ! Limbaj natural; 14:53 . . (+26) . . 178.138.98.136 ⓘ (discuție | blocare) (→*Vezi și: realism filst*) (revenire)
- (dif | ist) . . ! Realism (filozofie); 14:43 . . (-2) . . 178.138.98.136 ⓘ (discuție | blocare) (*plural*) (revenire)
- (dif | ist) . . ! Discuție:Norman Manea; 14:41 . . (+309) . . 178.138.98.136 ⓘ (discuție | blocare) (→*Paragraf în articol: pasaj extras, urmat de*) (revenire)
- (dif | ist) . . ! Discuție:Norman Manea; 14:36 . . (+625) . . 178.138.98.136 ⓘ (discuție | blocare) (*Secțiune nouă: →Paragraf în articol*) (Etichetă: Subiect nou)
- (dif | ist) . . ! Comuna Grivița, Vasiui; 14:29 . . (+202) . . 2a02:2f0e:6012:400:54dc:ce15:9f64:2d89 ⓘ (discuție | blocare) (→*Politică și administrație*) (Etichetă: Editare vizuală) (revenire)
- (dif | ist) . . m! Viorica Cosmetic; 14:27 . . (-8) . . Olga Valuta (discuție | contribuții | blocare) (Etichetă: Editare vizuală) (revenire | mulțumesc)
- (dif | ist) . . m! Clara; 14:17 . . (+87) . . Miau.Ham (discuție | contribuții | blocare) (*Mai multe detalii*) (Etichete: Editare vizuală, Modificare mobilă, Modificare de pe versiunea pentru mobil, Modificare avansată de pe mobil) (revenire | mulțumesc)
- (dif | ist) . . ! Viorica Cosmetic; 14:17 . . (+3.118) . . Olga Valuta (discuție | contribuții | blocare) (*s-a adăugat informație privind compania dată, informația o fost primită de la prima sursă*) (Etichetă: Editor vizual: Comutat) (mulțumesc)
- (dif | ist) . . ! Feleag, Mureș; 14:12 . . (+96) . . Andrei Rohan (discuție | contribuții | blocare) (→*istorie*) (Etichete: Modificare mobilă, Modificare de pe versiunea pentru mobil) (revenire | mulțumesc)

**WIKIMANIA**  
**KATOWICE**





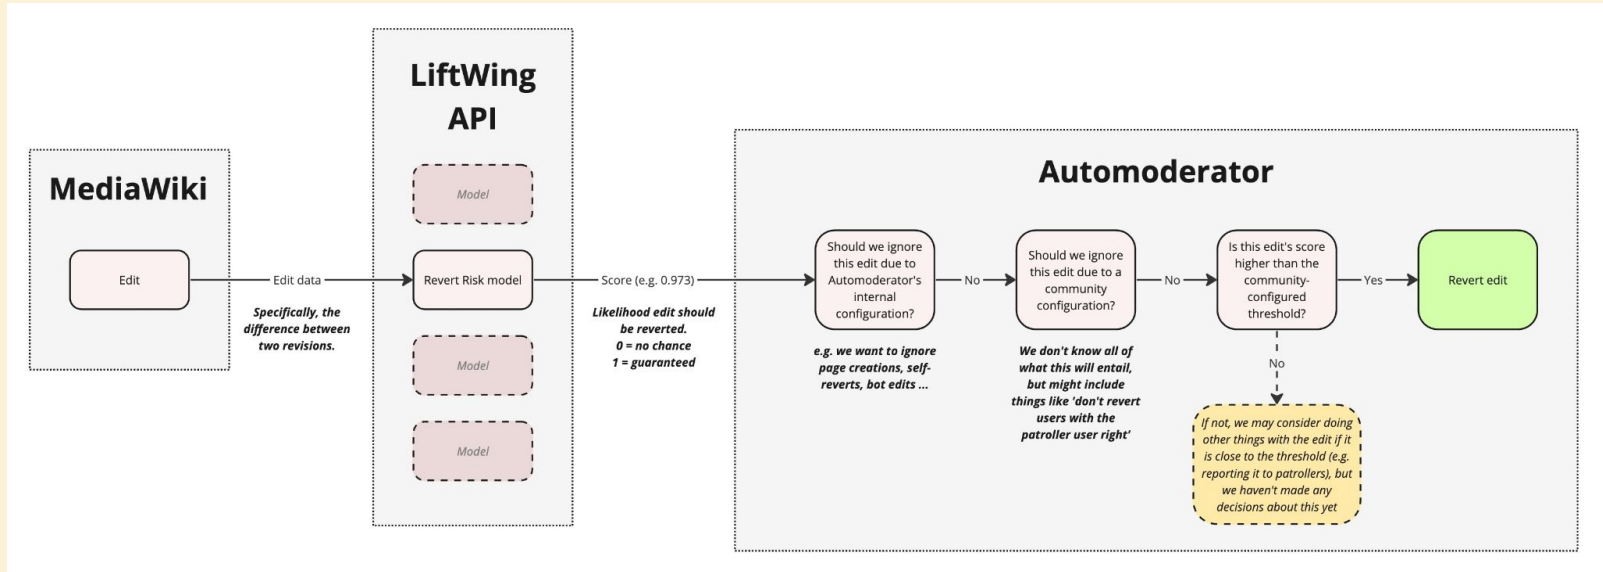
# How do AR work?

- o (dif | ist) . . **Nr** Discuție Utilizator:212.146.96.102; 10:28 . . (+1.388) . . PatrocleBot (discuție | contribuții | blocare) (Avertizare de nivel 1 pentru vandalism la Comuna Arefu, Argeș) (mulțumesc)
- o (dif | ist) . . **m** Comuna Arefu, Argeș; 10:28 . . (-52) . . PatrocleBot (discuție | contribuții | blocare) (Se revine automat asupra unei modificări distructive (scor revertrisk.multilingual: 0.9585068068085606). Greșit? Raportați aici.) (Etichetă: Revenire) (revenire | mulțumesc)
- o (dif | ist) . . Comuna Arefu, Argeș; 10:27 . . (+52) . . 212.146.96.102 ⓘ (discuție | blocare) (→Toponimie) (Etichete: Revenit, Editare vizuală, Edit Check (references) activated, Edit Check (referințe) respins (alt motiv))

**WIKIMANIA**  
**KATOWICE**



# How do AR work behind the scenes?



**WIKIMANIA**  
**KATOWICE**

Image by Samwalton9 (WMF), CC-BY-SA-4.0

[https://commons.wikimedia.org/wiki/File:Automoderator\\_and\\_Revert\\_Risk\\_decision\\_process.jpg](https://commons.wikimedia.org/wiki/File:Automoderator_and_Revert_Risk_decision_process.jpg)

# What is a “model”?

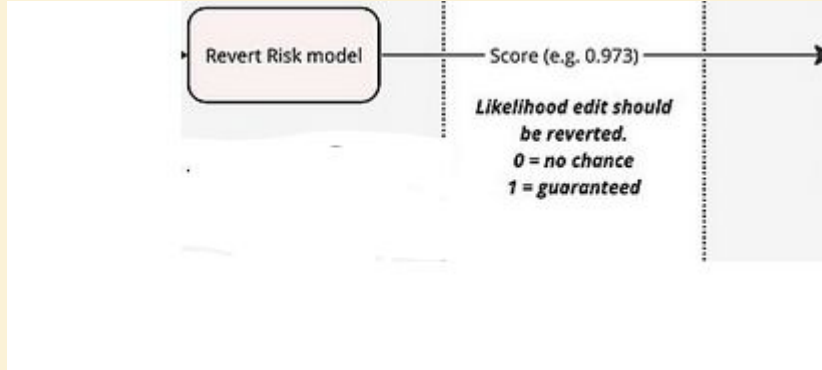
“A machine learning model is a type of [mathematical model](#) that, after being “**trained**” on a given dataset, can be used to **make predictions or classifications** on new data. During training, a learning algorithm iteratively adjusts the model's internal parameters to minimize errors in its predictions.”

[\[:en:Machine\\_learning#Models\]](#)

**WIKIMANIA**  
**KATOWICE**



# What is a “model”?



**WIKIMANIA**  
**KATOWICE**





# How to evaluate a

		Predicted condition	
		Positive (PP)	Negative (PN)
Actual condition	Total population = P + N		
	Positive (P)	True positive (TP)	False negative (FN)
	Negative (N)	False positive (FP)	True negative (TN)

[\[\[\[:en:Confusion matrix\]\]\]](#)

**WIKIMANIA**  
**KATOWICE**



# How to evaluate a

		Predicted condition	
		Positive (PP)	Negative (PN)
Actual condition	Positive (P)	True positive (TP)	False negative (FN)
	Negative (N)	False positive (FP)	True negative (TN)

Total population = P + N

$$\text{Precision} = \text{TP} / (\text{TP} + \text{FP})$$
$$\text{Recall} = \text{TP} / (\text{TP} + \text{FN})$$
$$\text{Accuracy} = (\text{TP} + \text{TN}) / (\text{P} + \text{N})$$

[\[\[\[:en:Confusion matrix\]\]\]](#)

**WIKIMANIA**  
**KATOWICE**



# How to evaluate a model?

“How much of the work does it do for me?”

**Automation = AR / TR**

Proposal: (auto reverts + auto patrols) / unpatrolled edits

**WIKIMANIA  
KATOWICE**



# Existing models: ORES

- Almost 10 years old!
- (Unjustly) considered as “legacy” and deprecated
- Customized models per language - lots of training effort!
- Provides several types of scoring, the relevant ones for AR being **damaging** and **goodfaith**.
- Currently used in the recent changes
- Works on revisions (covers 100% of edits)
- Optimizes recall
- Heavily biased against anonymous users

<https://www.mediawiki.org/wiki/ORES>

**WIKIMANIA**  
**KATOWICE**





# Existing models: ORES



**WIKIMANIA**  
**KATOWICE**

[https://commons.wikimedia.org/wiki/File:PatrocleBot\\_rowiki\\_thresholds.png](https://commons.wikimedia.org/wiki/File:PatrocleBot_rowiki_thresholds.png)

# Existing models: ORES

Patrol precision = 100%

Revert accuracy ~ 97%

Automation = 7.6%

Disclaimer: values calculated from historical stats, can be inaccurate

**WIKIMANIA**  
**KATOWICE**



# Existing models: language agnostic revert risk (RRLA)

- Uses more modern research than ORES
- Works everywhere without additional training
  - this is why Automoderator chose it
  - target accuracy = 90%
- Uses diffs, not revisions
  - doesn't work for new articles / non-articles
  - overall reach = 70% of revisions
- Biased on purpose against new/anon users

[https://meta.wikimedia.org/wiki/Machine\\_learning\\_models/Proposed/Language-agnostic\\_revert\\_risk](https://meta.wikimedia.org/wiki/Machine_learning_models/Proposed/Language-agnostic_revert_risk)

**WIKIMANIA**  
**KATOWICE**



# Existing models: RRLA

Threshold	Not cautious (0.97)	Low caution (0.975)	Somewhat cautious (0.98)	Cautious (0.985)	Very cautious (0.99)
Accuracy	75%	82%	93%	95%	100%
Automation	8.2%	5.5%	3.6%	1.8%	1.8%

Accuracy and rowiki automation per [WMF testing](#)  
Might be affected by local tooling!

**WIKIMANIA**  
**KATOWICE**

# Existing models: multilingual revert risk (RRML)

- Uses more modern research than ORES
- Works in 47 languages
- Uses diffs, not revisions
  - doesn't work for new articles / non-articles
  - overall reach = 70% of revisions
- Mitigates the bias against new/anon users
- Slower than the language-agnostic version

[https://meta.wikimedia.org/wiki/Machine\\_learning\\_models/Proposed/Multilingual\\_revert\\_risk](https://meta.wikimedia.org/wiki/Machine_learning_models/Proposed/Multilingual_revert_risk)

**WIKIMANIA**  
**KATOWICE**





# Existing models: RRML

Patrol precision = 100%

Revert accuracy ~ 97%

Automation = 22.2% (!)

Results from rowiki with .95 threshold  
for revert, same as ORES for patrol

**WIKIMANIA**  
**KATOWICE**



# RRML vs RRLA vs ORESd

Took ~3K unpatrolled changes on rowiki, ran both algorithms with thresholds at 0.93 and 0.95 and asked patrollers to evaluate if they would have reverted or not.

[original discussion](#)

[analysis from WMF Research](#)

**WIKIMANIA**  
**KATOWICE**



# RRML vs RRLA vs ORESd

Took random samples of recent changes and checked scores vs actual reverts

**WIKIMANIA**  
**KATOWICE**



# ML vs LA vs ORES conclusions

- RRML wins every time on every metric
- RRLA has decent accuracy, but poor precision
- ORES damaging by itself is about the same as RRLA

**WIKIMANIA**  
**KATOWICE**



# What does all this mean for you?

- Automated reverts are an awesome tool for patrollers
- Automoderator seems to be a promising, balanced tool, but with limited impact → we should lobby WMF to improve the models further and use more models where available
- If you have technical knowledge in the community, there are better options out there.

**WIKIMANIA**  
**KATOWICE**





# Questions

WIKIMANIA  
KATOWICE

