

Personalization@ZDF

DR



Team Personalization & Automation at ZDF



Xenija




Bernhard



Jan




Ronny



Florian



Jana



Paul



Charlotte



Valentin




Johanna




Jan



Venkata



Christian







Andreas

I UseCases, algorithms, metrics

Recommendations ZDFmediathek

- 50% of viewing volume from start page generated by automatic recommendations
- 20% of content catalog automatically recommended and used every day
- 60% of SmartTV users click on personalized recommendations

Our goal: mostly complete automation and personalization of ZDFmediathek compliant to our public service media



Metrics & values: a pragmatic approach (2019)






#1 User centric: always relevant and available

#2 Measurable: watch time, outreach, diversity und coverage

#3 Free and transparent: no mandatory login, no hidden barriers


Metrics & values: a pragmatic approach (2019)




- Orders of magnitude **more distinct content** items watched
- **More niche content** is watched
- **„Mechanical diversity“** (randomness, forcing different programs) is helpful for business KPIs
- **High user engagement:** most clicked cluster on web and Smart TV
- **Simple algorithms** partially competitive
- **Open question: ML metrics - a good proxy** for business KPIs? A/B-Tests!

Recommendations ZDFmediathek


Do we comply to our public service media remit (PSMR)?



So streamt der Sommer



Das könnte Dich interessieren



Serien-Highlights




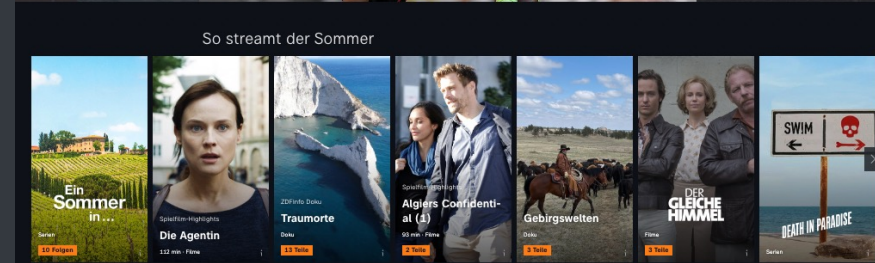

Public Service Media Values

What is the public service media remit (PSMR)?

- provide education, information, advice and entertainment, in particular culture...
- follow principles of objectivity and impartiality of reporting, diversity of opinion and the balance of offerings...

(1) Auftrag der öffentlich-rechtlichen Rundfunkanstalten ist, durch die Herstellung und Verbreitung ihrer Angebote als Medium und Faktor des Prozesses freier individueller und öffentlicher Meinungsbildung zu wirken und dadurch die demokratischen, sozialen und kulturellen Bedürfnisse der Gesellschaft zu erfüllen. Die öffentlich-rechtlichen Rundfunkanstalten haben in ihren Angeboten einen umfassenden Überblick über das internationale, europäische, nationale und regionale Geschehen in allen wesentlichen Lebensbereichen zu geben. Sie sollen hierdurch die internationale Verständigung, die europäische Integration und den gesellschaftlichen Zusammenhalt in Bund und Ländern fördern. Ihre Angebote haben der Bildung, Information, Beratung und Unterhaltung zu dienen. Sie haben Beiträge insbesondere zur Kultur anzubieten. Auch Unterhaltung soll einem öffentlich-rechtlichen Angebotsprofil entsprechen.

(2) Die öffentlich-rechtlichen Rundfunkanstalten haben bei der Erfüllung ihres Auftrags die Grundsätze der Objektivität und Unparteilichkeit der Berichterstattung, die Meinungsvielfalt sowie die Ausgewogenheit ihrer Angebote zu berücksichtigen.



Public service media remit and metrics



Boards / regulators



Editors



Audience



Content partners



Data / ML

§ 26
Auftrag

(1) Auftrag der öffentlich-rechtlichen Rundfunkanstalten ist, durch die Herstellung und Verbreitung ihrer Angebote als Medium und Faktor des Prozesses freier individueller und öffentlicher Meinungsbildung zu wirken und dadurch die demokratischen, sozialen und kulturellen Bedürfnisse der Gesellschaft zu erfüllen. Die öffentlich-rechtlichen Rundfunkanstalten haben in ihren Angeboten einen umfassenden Überblick über die nationale und regionale Geschehnisse in allen wesentlichen Lebensbereichen zu geben, sie sollen durch die internationale Verständigung, die europäische Integration und den gesellschaftlichen Zusammenhalt in Bund und Ländern fördern. Ihre Angebote haben der Bildung, Information, Beratung und Unterhaltung zu dienen. Sie haben Beiträge insbesondere zur Kultur anzubieten. Auch Unterhaltung soll einem öffentlich-rechtlichen Angebotsprofil entsprechen.

(2) Die öffentlich-rechtlichen Rundfunkanstalten haben bei der Erfüllung ihres Auftrags die Grundsätze der Objektivität und Unparteilichkeit der Berichterstattung, die Meinungsvielfalt sowie die Ausgewogenheit ihrer Angebote zu berücksichtigen.

Product

```
item = tf.keras.layers.Input(shape=(1, ), name="mlp_item")
i = tf.keras.layers.Embedding(n_items, n_factors, name="mlp_item_emb")(item)
i = tf.keras.layers.Reshape((n_factors, ), name="mlp_item_reshape")(i)

# mlp hidden layers
ui = tf.keras.layers.Concatenate(axis=1)([u, i])
hidden1 = tf.keras.layers.Dense(
    n_factors * 2, activation="relu", name="mlp_layer_1"
)(ui)
hidden2 = tf.keras.layers.Dense(
    n_factors * 2, activation="relu", name="mlp_layer_2"
)(hidden1)
hidden3 = tf.keras.layers.Dense(
    n_factors // 2, activation="relu", name="mlp_layer_3"
)(hidden2)

# compute recommendations
predictions = tf.keras.layers.Dense(1, activation="sigmoid", name="mlp_score")(
```

PSM Values

Impartiality, Transparency...

PSM Metrics

Coverage: how much of the catalog?

Novelty: how often niche content?

Diversity: how diverse is the content?

Serendipity: how often is content outside prior known areas of interest?

IR Metrics

MRR, NDCG,

HR...

Use case „Newly available...“

- Automate content cluster (last manually curated at ZDFInfo)
- Evaluate Bandits as recommender system
- Optimize PSM metrics through exploration




New content + editorial promotion



Multi-Armed Bandit

Multi-Armed Bandits: Clicks, Coverage and Topic Diversity

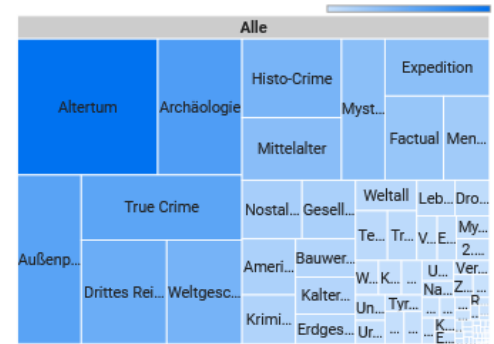

Clicks in A/B-



Tags aller empfohlenen Content-Items



Tags aller empfohlenen Content-Items



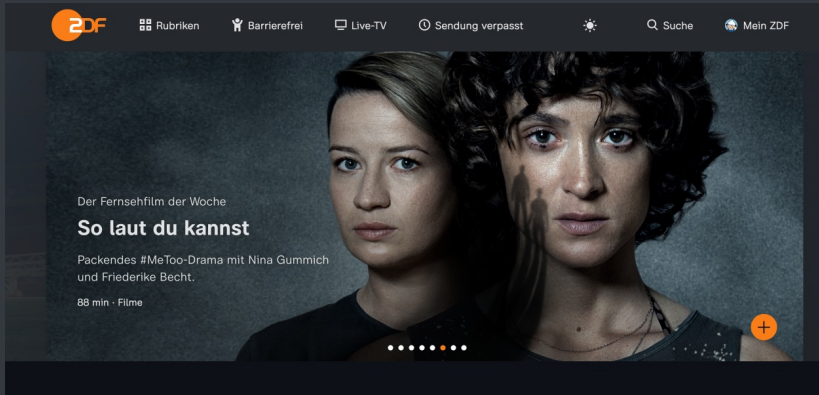
No Diversity without Diverse Content

Diverse content

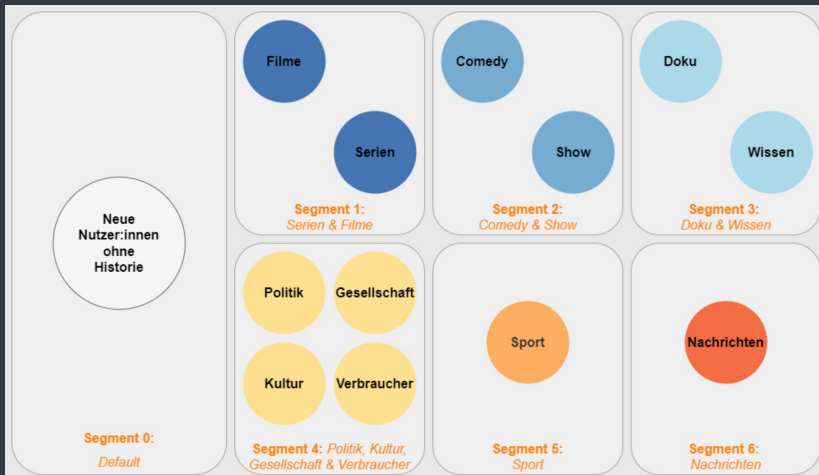


+ Metadata
making Diversity
actionable

UseCase „Personalized Stage“



- Goal: Diversity for new users and serendipity for known users
- Balancing editorial and automated recommendations
- Algorithmn: contextual multi armend bandit with user segment as context





UseCase „Personalized Stage“: first results

- Diversity: 150 different content items on the automated teaser positions each day
- High number of clicks related to teaser position for automated teaser positions
- Next steps: more context, additional KPIs
- Details:

<https://algorithmen.zdf.de/awf/pb>

(german)



II Transparency and Exchange



01.03.23

Die ZDFmediathek ist heute ein vielfach personalisiertes und automatisiertes Angebot, an vielen Stellen sind Algorithmen im Einsatz. Wir erklären euch hier, wie diese Algorithmen funktionieren, welche Daten dabei verwendet werden und vor allem, wie sie uns dabei helfen, unseren öffentlich-rechtlichen Auftrag umzusetzen. Weiter unten sind die derzeitigen Inhalte gelistet. Wir entwickeln diese Seite ständig weiter, es lohnt sich also immer wieder hier reinzuschauen.

Unsere Metriken und Kennzahlen

Metriken und Kennzahlen brauchen wir, um von den recht abstrakten Regelungen des öffentlich-rechtlichen Auftrags die Brücke zu den konkreten verwendeten Daten und Algorithmen schlagen zu können. Anders als für viele Streaming-Plattformen ist uns zum Beispiel die Vielfalt oder Diversität der empfohlenen Inhalte sehr wichtig.

Anwendungsfälle in der ZDFmediathek

Ruft man die ZDFmediathek auf, zeigt die Seite verschiedene Bänder mit Empfehlungen. Solche Empfehlungsbänder funktionieren nach festgelegten Regeln, die wir Anwendungsfälle nennen. Konkret beschreiben wir für verschiedene Anwendungsfälle, welches publizistische Ziel wir verfolgen, welche Daten und

algorithmen.zdf.de

- Explain use cases, metrics and algorithms used
- Deal openly with own limitations and weaknesses
- Blog: talk to your users

Transparency is the basis for an informed discussion and building trust

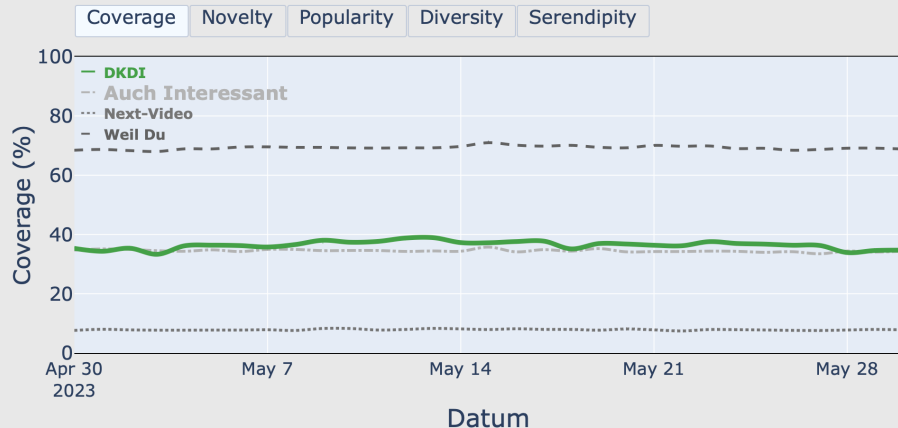
algorithmen.zdf.de: metrics

Coverage

Die Metrik **Coverage** beschreibt, wie viele Videos vom Gesamtbestand der **ZDFmediathek** den Nutzerinnen und Nutzern wirklich empfohlen werden.

Wären beispielsweise in der ZDFmediathek insgesamt 100 Videos verfügbar und der Algorithmus würde im Laufe des Tages 80 davon empfehlen, dann läge die Coverage bei 80%.

Wieso ist das öffentlich-rechtlich? Die Inhalte der Mediathek wurden vom Rundfunkbeitrag finanziert und sollen möglichst alle Personen in Deutschland abholen - mit unterschiedlichen Interessen, Vorwissen und Lebenssituationen. Daher sollten die Algorithmen möglichst alle Inhalte, also das gesamte Programmvermögen des ZDF und der Content-Partner anbieten, und nicht nur die erfolgreichsten und neuesten.



metrics make algorithms measurable

- Classic metrics: viewing volume, click through rate...
- Public value metrics: diversity, coverage, serendipity and novelty
- Importance of individual metrics varies per use case
- Metrics are constantly evolving (e.g. popularity added lately)

algorithmen.zdf.de: UseCase „Weil Du...“

Modell

Machine Learning Algorithmen werden mit Hilfe von verschiedenen Daten trainiert. Das Ergebnis dieses Trainings ist ein Modell. Hier kann es je nach Anwendungsfall zu wesentlichen Unterschieden kommen, die auch eine Auswirkung auf das Ergebnis haben.

Preprocessing. In einem ersten Schritt, findet eine Vorauswahl statt, um die gewünschten Daten für das Modelltraining bereitzustellen:

- Filterung der Nutzungshistorie nach Pfaden (Speicherorten) im redaktionellen Content Management System
- Zufälliges Sampling der Referenz-Beiträge aus gefilterter Nutzungshistorie

Basis-Algorithmus. Um unsere Modelle zu trainieren, verwenden wir Algorithmen, die auf Erkenntnissen der Wissenschaft basieren. Folgende Basis-Algorithmen und Quellen haben wir hier verwendet:

- [A/B-Gruppen A und D: Collaborative Filtering und Text Modell](#)
 - Paper Collaborative Filtering: [Collaborative Filtering for Implicit Feedback Datasets](#) und [Applications of the Conjugate Gradient Method for Implicit Feedback Collaborative Filtering](#)
 - Implementierung Collaborative Filtering: [Open source 3rd party Basis-Framework "implicit"](#)
 - Implementierung Text Model [scikit-learn TfidfVectorizer](#) mit [spacy stopwords](#) und [nmslib](#) zur Abstandsberechnung.
- Gruppe B: Collaborative Filtering
 - Paper Collaborative Filtering: [Collaborative Filtering for Implicit Feedback Datasets](#) und [Applications of the Conjugate Gradient Method for Implicit Feedback Collaborative Filtering](#)
 - Implementierung Collaborative Filtering: [Open source 3rd party Basis-Framework "implicit"](#)
- Gruppe C: Sequence Base Recommendation
 - Paper: [Session-based Recommendations with Recurrent Neural Networks](#) (Hidasi et al.)
 - Implementierung: [Open source 3rd party Basis-Framework "spotlight"](#)

Collaborative Filtering for Implicit Feedback Datasets

Yifan Hu
AT&T Labs – Research
Florham Park, NJ 07932

Yehuda Koren*
Yahoo! Research
Haifa 31905, Israel

Chris Volinsky
AT&T Labs – Research
Florham Park, NJ 07932

Abstract

A common task of recommender systems is to base recommendations on prior implicit feedback. We track different sorts of user behavior, such as purchase history, watching habits and browsing history, to improve recommendation performance. This paper describes our approach.

SESSION-BASED RECOMMENDATIONS WITH RECURRENT NEURAL NETWORKS

Balázs Hidasi*
Gravity R&D Inc.
Budapest, Hungary
balazs.hidasi@gravityrd.com


Linus Baltrunas†
Netflix
Los Gatos, CA, USA
lbaltrunas@netflix.com

ABSTRACT

We apply recurrent neural networks (RNNs) to session-based recommendation systems. Real-life recommender systems often do not have long user histories (as on a website) instead of long user histories (as on a frequently praised matrix factorization method). Matrix factorization is usually overcome in practice by recommending similar items. We argue that more accurate recommendations can be provided by session-based approaches. We present practical aspects of the task and introduce a ranking loss function that makes experimental results on two data-sets show that our approach is better.

The image shows two overlapping screenshots of GitHub repositories. The top one is for 'benfred/implicit', showing a pull request titled 'Add an alpha parameter for the ALS models (#581)'. The bottom one is for 'nmslib/nmslib', showing a file tree with folders like 'docs', 'integration_tests', 'notebooks', 'tensorflow', 'tests', and files like 'LICENSE', 'LICENSE-Apache-2.0', 'MANIFEST.in', and 'README.md'.

algorithmen.zdf.de: insights into popularity debiasing



Countering Popularity Bias by Regularizing Score Differences

Wondo Rhee

wondo94@snu.ac.kr

Dept. of Intelligence and Information,
Seoul National University
Republic of Korea

Sung Min Cho

tjdals4565@snu.ac.kr

Dept. of Computer Science and
Engineering, Seoul National
University
Republic of Korea

Bongwon Suh

bongwon@snu.ac.kr


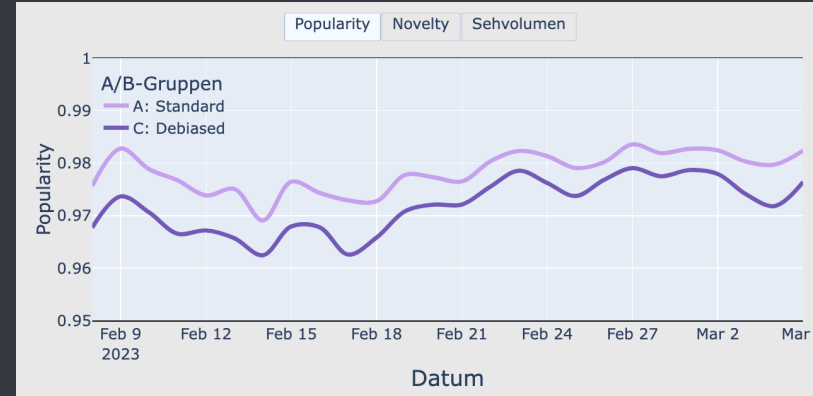
Dept. of Intelligence and Information,
Seoul National University
Republic of Korea

ABSTRACT

Recommendation system often suffers from popularity bias. Often the training data inherently exhibits long-tail distribution in item popularity (data bias). Moreover, the recommendation systems could give unfairly higher recommendation scores to popular items even among items a user equally liked, resulting in over-recommendation of popular items (model bias). In this study we propose a novel method to reduce the model bias while maintaining

1 INTRODUCTION

Recommendation systems are used in many domains such as e-commerce, movie, and music [4, 5, 19]. Often recommendation systems learn the user preference from the implicit feedback information such as clicks, purchase, and item consumption [17, 26, 42]. Meanwhile, the systems are prone to popularity bias, which can come in many forms [2, 8, 9, 29]. From the data side, the user-item feedback data shows long tail distribution in item frequency with most inter-




Networking and Exchange

PSM



Academia

NGO & Conferences



Open Sourcing

- Planned first step: publication of "pa-base" package
- Contains configuration handling, auxiliary functions for data handling, data structures, pre/postprocessing
- Next: other components, models

```
# Copyright (c) 2023, ZDF.
```

```
"""
```

```
This module implements a simple model capable of generating scored predictions.
```

```
"""
```

```
import logging
import pickle
from abc import ABC, abstractmethod
from typing import BinaryIO, Iterable, List, Tuple, TypeVar
```

```
import numpy as np
```

```
from pa_base.data.s3_util import s3_file
```

```
class PredictMixin(ABC):
```

```
    @abstractmethod
```

```
    def predict(
```

```
        self,
        sequence: Iterable[str],
```

```
        *,
```

```
        select: Iterable[str] = (),
```

```
        n: int = None,
```

```
        scale: bool = False,
```

```
        **kwargs,
```

```
    ) -> List[Tuple[str, float]]:
```

```
        """get predictions for sequence of interactions
```

```
        :param sequence: user history from newest to oldest
```

```
        :param select: allowed items' externalids
```

```
        :param n: max. number of returned items or None for all items
```

```
        :param scale: whether scores should be scaled to [0,1]
```

```
        :param kwargs: model-specific params
```

```
        :return iterable of (externalid, score) tuples
```

```
        """
```

```
        raise NotImplementedError(
```

```
            "Subclasses should overwrite this if it fits their use case"
```

```
        )
```

III Sustainability

Green recommendations:

"Carbon Neutrality is ZDF's Sustainability Goal #1*"

Strategies to reduce power consumption

#1 Algorithms & Model training

- Shallow models
- Data efficiency
- Incremental/online training
- User segments

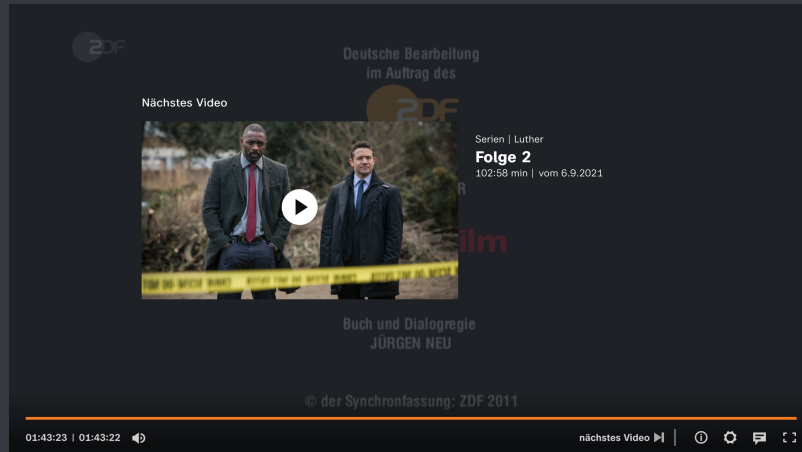
#2 Inference & serving recos

- Caching while staying fresh
- Adaptive precomputation
- User segments

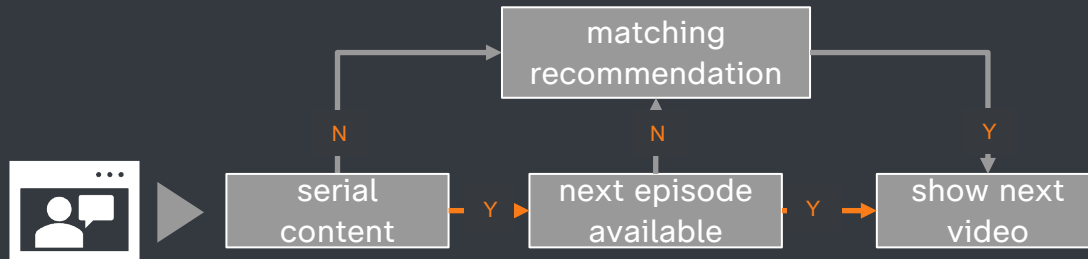
What's next?

As announced at ACM RecSys 2021: intensify focus on green recommendations

Green recommendations: use case „next video“



- ✓ Rule based for serial content
- ✓ data efficient
- ✓ incremental retraining
- x Energy efficient



Next-Video: Green Recommendations

Green Recommendations

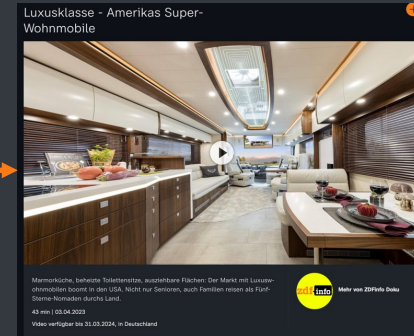
Can we save some energy without sacrificing quality?

Calculation basis: number of servers and estimated power consumption

A/B-Test Next Video

Gruppen A + C (30%): sequence based

Gruppe B (30%): c2c with SLM



Group A




Group B


Next-Video: Green Recommendations

Preliminary results


Training & Embeddings



Inference



Similar Click Rates



How we do public service media recommendations

I UseCases, algorithms, metrics

- One remit, many metrics
- UseCases need specific algorithms and metrics. It is not „the one and only public service media algorithm.“
- Escape your own past: exploration is key! Implementation with bandits & reinforcement learning

II Transparency and exchange

- Whatever we do must be publicly explained, without any ifs and buts
- More participation: open source
- Networking, exchange and competition are not only nice, but necessary to remain competitive

III Sustainability

- Energy efficient, simple algorithms
- Model Reuse: one trained model for different UseCases
- Do not personalize everything, automation might be enough
- How individual does personalization have to be and how data saving can it be?

Information pointer

ACM RecSys Talks



ACM RecSys Papers 2021 - 2023

