



HAL
open science

Estimer automatiquement les différences de représentation existant entre les femmes et les hommes dans les médias

David Doukhan, Zohra Rezgui, Géraldine Poels, Jean Carrive

► To cite this version:

David Doukhan, Zohra Rezgui, Géraldine Poels, Jean Carrive. Estimer automatiquement les différences de représentation existant entre les femmes et les hommes dans les médias. journée DAHLIA : "Informatique et Humanités numériques : quelles problématiques pour quels domaines?", Jun 2019, Nantes, France. hal-02168148

HAL Id: hal-02168148

<https://hal.science/hal-02168148>

Submitted on 28 Jun 2019

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Estimer automatiquement les différences de représentation existant entre les femmes et les hommes dans les médias

David Doukhan, Zohra Rezgui, Géraldine Poels, Jean Carrive

Institut national de l’audiovisuel (INA)
4 avenue de l’Europe, 94366 Bry sur Marne Cedex, France
{ddoukhan,zrezgui,gpoels,jcarrive}@ina.fr

1 Introduction

Alors que la question de la représentation médiatique des femmes est au cœur du débat public, on manque encore de méthodes et d’outils robustes pour élaborer des indicateurs aussi simples que le temps de parole ou de présence à l’écran. Faute de quoi, il est très difficile de proposer des études mettant en évidence des évolutions, reposant sur l’analyse de corpus significatifs. Ainsi, l’indicateur quantitatif le plus couramment utilisé est le *taux de présence* (Reiser et Gresy, 2008; CSA, 2017), qui consiste à compter (et souvent catégoriser) le nombre de personnes différentes présentes dans les programmes (expert, journaliste, témoin anonyme). D’autres indicateurs ont été proposés pour préciser ces descriptions : notamment le *taux d’expression* (pourcentage de temps de parole attribué aux femmes et aux hommes), ainsi que le *taux d’identification* (nombre de mentions orales faisant référence à des hommes ou à des femmes) (Reiser et Gresy, 2008). La mesure manuelle de ces indicateurs est coûteuse, et peut nécessiter de 10 à 20 fois le temps de visionnage des documents. Pour cette raison, les rares études portant sur le taux d’expression et d’identification ont jusqu’ici été réalisées sur des quantités limitées de documents, induisant un certain nombre de biais d’analyse.

Dans le cadre de cette étude, nous présentons dans un premier temps les résultats obtenus à large échelle lors de travaux précédents, fondés sur l’analyse automatique du *taux d’expression* (Doukhan, 2019). Nous décrivons dans un second temps les travaux en cours visant à décrire automatiquement le *taux d’identification* ainsi que le *taux d’exposition visuelle*.

2 Taux d’expression à la télévision et à la radio

Plus d’un million d’heures d’émissions TV (34 chaînes) et radio (21 stations) diffusées de 1995 à 2019 ont été analysées à l’aide du logiciel open-source `inaSpeechSegmenter` permettant de localiser automatiquement les zones de parole et de prédire le sexe des locuteurs (Doukhan et al., 2018). La voix chantée est assimilée à de la musique, et ne fait pas l’objet d’une classification en genre. L’ensemble des mesures obtenues a été rendu disponible en open-data¹. Les analyses réalisées ont montré que le taux d’expression des femmes a évolué de

1. <https://www.data.gouv.fr/fr/organizations/institut-national-de-laudiovisuel/>

Estimer automatiquement les différences de représentation entre les femmes et les hommes

25.1% en 2001 à 34.4% en 2018. Nous avons également observé que les femmes parlent moins aux heures de forte audience sur les chaînes privées. Les *taux d'expression* obtenus en 2016 sont généralement inférieurs aux *taux de présence* mentionnés dans le rapport du CSA (-4.4 points pour la radio et -9.1 points pour la TV)(CSA, 2017), ce qui suggère qu'à présence égale, les femmes parlent moins que les hommes dans les médias.

3 Estimation multi-critères de la représentation des femmes

Un système de détection des visages dans les vidéos et de prédiction du sexe de la personne à l'écran a été réalisé (taux de bonne classification 95.2% sur Youtube Faces). Un prototype d'estimation du *taux d'identification*, utilisant le système de transcription de la parole du LIUM (Laboratoire d'Informatique de l'Université du Mans), permet le décompte des mentions orales faisant référence à des hommes ou à des femmes à l'aide de règles lexicométriques simples (dictionnaire de prénoms, liste de mots cibles : fille, monsieur, mec...). La table 1 détaille les résultats obtenus par les trois systèmes, utilisés pour analyser l'ensemble des programmes diffusés la semaine du 8 avril 2019 de 10h à 24h sur 6 chaînes TV (588 heures). Les descripteurs obtenus semblent indiquer qu'on voit davantage les femmes qu'on ne les entend, plus particulièrement sur Canal+. Les analyses portant sur le lexique utilisé pour désigner les femmes ont indiqué une forte disparité entre les chaînes dans l'usage du terme *mademoiselle*.

chaîne	TF1	France 2	France 3	Canal+	Arte	M6
parole (%)	38.8	40.5	34.1	22.4	32.1	44.5
visages (%)	45.4	47.3	35.6	31.5	33.0	49.4
mentions orales (%)	42.6	45.9	42.6	33.2	39.5	45.8

TAB. 1 – Pourcentages de parole, de visages et de mentions orales attribués à des femmes

Références

- CSA (2017). La représentation des femmes à la télévision et à la radio. rapport sur l'ex. 2016.
- Doukhan, D. (2019). À la radio et à la télé, les femmes parlent deux fois moins que les hommes. *La revue des Médias Femmes dans les médias : rôles de dames - épisode 2/8*.
- Doukhan, D., J. Carrive, F. Vallet, A. Larcher, et S. Meignier (2018). An open-source speaker gender detection framework for monitoring gender equality. In *ICASSP*. IEEE.
- Reiser, M. et B. Gresy (2008). L'image des femmes dans les médias. *Rapport public*.

Summary

Large scale gender representation analysis in French TV and radio is presented, based on automatic information extraction procedures: speech time (1 million hours of programs), number of oral references to characters (588 hours) and visual exposition time (588 hours).