



# Cluster Analysis of Role Languages in Visual Novel Game *AIR*

---

ASIAN 358 Japanese Sociolinguistics:  
Final Presentation (2024/12/5)

Ruixuan Tu (ruixuan.tu@wisc.edu)






# Role Language “Yakuwarigo” and “特徵語”

---

- **“Yakuwarigo” (defined on individual character):** sets of spoken language features (e.g. vocabulary and grammar) and phonetic characteristics (e.g. intonation and accent patterns), associated with particular character types (Kinsui 2003 as cited in Teshigawara & Kinsui 2012)
- **Keyword “特徵語” (defined on group): significant** ( $\text{CoS} > 2$ ) and minor ( $\text{CoS} < 0.5$ ) words (Ma 2019)
- **Coefficient of Specialization of Word in Cluster “特化係数”:**  
$$\text{CoS}(W,C) = \frac{\text{freq of } W \text{ in cluster } C}{\text{number of words in cluster } C} / \frac{\text{freq of } W \text{ in whole}}{\text{number of words in whole}}$$
- **RQ:** Keyword → Yakuwarigo? **Example:** AIR

# Cluster Analysis Technical Terms

- Distance between clusters:** Ward's method
  - Metric: increase of **Sum of Squares** when we merge two clusters:  $d(A, B) = \frac{|A| \cdot |B|}{|A \cup B|} \|\mu_A - \mu_B\|_2^2$
  - Idea: minimize variance from cluster centers
  - Connection:  
 $SS = \sum (x_i - \bar{x})^2$ ; variance  $s^2 = \frac{SS}{n-1}$
- Distance between points:** Euclidean  
 $d(\mathbf{x}, \mathbf{y})^2 = \|\mathbf{x} - \mathbf{y}\|_2^2 = \sum_{i=1}^n (x_i - y_i)^2$





# AIR (2000): Visual Novel Game and Data

少年少女の恋愛劇に不可思議要素を絡めたアドベンチャーゲームであり、シナリオが感動に特化した泣きゲーとして支持を集めた。



**Volumes:** "Dream (Yukito & Misuzu)", "Summer (Kanna, 1000 years ago)", "Air (Misuzu only)"

**Script:** 麻枝准、イシカワタカシ

**Scenario Assistant:** 涼元悠一、雲龍寺魁、丘野塔也、藤井知貴

Line	Type	Speaker	Text
SEEN0180-885	dialogue	観鈴	「わ、すごい…掴んだ」
SEEN0180-887	dialogue	往人	「なんだ、セミか…」
SEEN0180-890	dialogue	観鈴	「わわわーっ！」
SEEN0180-891	dialogue	観鈴	「放さないでっ！」
SEEN0180-893	dialogue	観鈴	「わ、また掴んだ…」
SEEN0180-894	dialogue	往人	「…どうすればいいんだ、俺は」
SEEN0180-895	dialogue	観鈴	「外っ。はいはいっ」
SEEN0180-896	dialogue	往人	「……」
SEEN0180-898	dialogue	観鈴	「はい、放してー」
SEEN0180-901	dialogue	観鈴	「ふう…」
SEEN0180-902	dialogue	往人	「騒がしいやつだな」
SEEN0180-903	dialogue	観鈴	「騒がしいのはセミっ。わたしじゃないの」
SEEN0180-904	dialogue	観鈴	「換気扇から、たまに入ってくるの」
SEEN0180-905	dialogue	往人	「ふうん…」
SEEN0180-906	dialogue	観鈴	「でも、すごく器用。飛んでるセミを掴めるなんて」
SEEN0180-907	dialogue	往人	「そうか？」


# AIR: Preparation for Quantitative Analysis

1. **Select** analyzable speakers with >100 lines
2. **Split** tokens by morpheme analyzer
3. Adjusted Frequency for Word and Speaker  $T(S, W)$ :

$$10000 \times \frac{\text{freq of } W \text{ in speaker } S}{\text{number of words in speaker } S}$$


(frequency of  $W$  per 10000 words for speaker  $S$ )

4. Adjusted Frequency Table for (word, speaker) pairs



# AIR: Cluster Analysis

- **Input:** every column of adjusted frequency table  
 $T(S) = (T(S, W_1), \dots, T(S, W_n))$
- **Output:** clusters
  - Cluster 0: non-female language (往人)
  - Cluster 1: casual female language (観鈴)
  - Cluster 2: formal and polite language (美凪)
  - Cluster 3: dialectal language (晴子)



# AIR: Extraction of Role Language

- **Calculate Coefficient of Specialization, select** significant and minor morphemes, **rank** by high frequency
  - **Confirm** clusters:
    - Cluster 0: non-female language
    - Cluster 1: casual female language
    - Cluster 2: formal and polite language
    - Cluster 3: dialectal language

CN	Pron (代名)	Aux Verb (助動)	Case Part (格助)	Adv Part (副助)	Conj Part (接続)	Final Part (終助)	Noun Part (準体)	Interj (感動)
	神奈 only		してろ=していろ					
0	俺 (2.24, 551) おまえ (2.23, 469) 君 (2.18, 111) 余 (2.19, 95) あいつ (2.13, 57)	だろ (2.18, 378) だろう (2.14, 147) てろ (2.17, 33) だろっ (2.24, 19)		ぞ (2.2, 161) ツ (2.24, 7)		ぞ (2.17, 477) ぜ (2.16, 55)		ああ (2.07, 501) いや (2.1, 202) おい (2.19, 45) うむ (2.24, 42) ぐはつ (2.24, 28)
1	わたし (3.31, 402) あたし (3.3, 78) うぬ (3.34, 57) キミ (3.34, 12) ふん (3.34, 7)	ちゃつ (3.06, 100) ちゃう (2.64, 68) ね (2.61, 64) だあ (3.09, 38) たー (3.08, 36)	とつ (2.13, 78) ~ (2.54, 32) でー (2.0, 9) じゃあ (3.43, 8) にい (3.34, 5)		し (2.15, 135) に (3.34, 36) ぱっかり (2.34, 7)	ね (2.71, 848) よお (3.24, 234) ちや (2.38, 30) じゃあ (3.34, 10) からあ (3.34, 6)		うん (2.83, 485) あ (2.07, 128) うーん (3.09, 98) えっと (2.31, 91) うんっ (3.34, 88)
2	私 (5.92, 149) わたくし (9.56, 39) こちら (6.32, 15) どちら (4.86, 6)	です (7.58, 410) ます (8.4, 381) で (2.13, 220) まし (7.65, 167) ませ (8.51, 126)		など (4.21, 18) ばかり (2.04, 6) さえ (2.39, 5)	ながら (2.4, 13) とも (6.02, 8)			はい (7.05, 184) あ (2.08, 31) えっと (2.3, 29) ありがとう (6.27, 25) いえ (9.3, 15)
3	あんた (4.78, 312) なん (2.13, 157) うち (6.3, 26) かん (6.3, 20) わらわ (3.5, 10)	や (6.05, 589) たら (2.23, 217) やる (6.14, 160) へん (6.25, 139) せ (3.49, 101)		や (5.92, 603) なんか (2.54, 42) て (3.45, 17) かー (4.72, 6) なん (6.3, 5)	で (2.24, 126) たって (3.43, 12) ど (3.33, 9) さかい (6.3, 6) なー (3.65, 77)	わ (3.16, 186) ねん (5.84, 116) や (5.55, 82) い (4.35, 78) なー (3.65, 77)		ん (3.89, 94) ほな (6.3, 62) ええ (4.97, 45) よっしゃ (6.3, 20) よし (2.38, 20)
0	あんた (0.45, 83)	ます (0.2, 43) です (0.1, 25) まし (0.16, 16) や (0.05, 13) ませ (0.16, 11)	ずっと (0.13, 7)	なんか (0.5, 23) や (0.06, 17) たり (0.41, 15) て (0.43, 6)	し (0.49, 46) ちや (0.43, 8)	ね (0.05, 25) い (0.42, 21) なあ (0.21, 19) ねえ (0.25, 17) わ (0.07, 11)		はい (0.3, 37) うん (0.12, 31) あ (0.33, 30) あ (0.4, 28) えつ (0.46, 12)
1	何 (0.47, 33) あんた (0.13, 16) こいつ (0.41, 9)	ます (0.33, 47) なら (0.38, 28) せ (0.24, 13) だろ (0.09, 11) や (0.05, 10)	を (0.45, 244)	や (0.06, 11)	が (0.35, 30)	な (0.45, 337) い (0.38, 13) ぞ (0.08, 12) なあ (0.45, 7) や (0.18, 5)		ええ (0.35, 6) ありがとう (0.4, 5) いや (0.08, 5) ああ (0.03, 5)
2	なん (0.29, 13) どこ (0.44, 7)	だ (0.18, 68) たら (0.34, 20) てる (0.21, 16) じゃ (0.24, 11) だっ (0.21, 7)	って (0.29, 19)	や (0.16, 10)		よ (0.46, 62) の (0.25, 5)		ああ (0.14, 7) ん (0.42, 6)
3	何 (0.48, 18)	ない (0.16, 34) だ (0.05, 31) です (0.15, 14) ませ (0.44, 11) ます (0.09, 7)	を (0.37, 107)		ば (0.4, 27)	よ (0.21, 46) ね (0.14, 24) の (0.27, 9)		ああ (0.35, 30) いや (0.23, 8) うん (0.08, 7)



# AIR: Exceptions in Non-female Language

- **Pron 「余」 by Kanna 神奈:**  
Lived 1000 years ago,  
goddess in a shrine, last  
winged beings (翼人), calm  
speaking; met Ryuya 柳也  
and Uraha 裏葉 to escape  
and meet her mother
- **Interj 「うむ」 by Hijiri 聖、  
Kanna 神奈-majority**  
Elder sister of Kano 佳乃,  
doctor at Kirishima Clinic,  
always carry a lancet
- →Non-typical female  
language



43795	SEEN0700-91	dialogue	神奈	なにゆえ、余が案内せねばならぬ
43799	SEEN0700-95	dialogue	神奈	なにゆえ、余が、おぬしを、案内せねば、ならぬ？
43817	SEEN0700-113	dialogue	神奈	なにゆえに、余は閉じ込められねばならぬのだ
43818	SEEN0700-114	dialogue	神奈	余はひとりでも生きてゆけるぞ…
43852	SEEN0700-148	dialogue	神奈	余はここで暮らしておる
...	...	...	...	...
48523	SEEN0702-1593	dialogue	神奈	余の夢だ…
48545	SEEN0702-1615	dialogue	神奈	余の最後の命である
48986	SEEN0703-290	dialogue	神奈	…余の命であるぞ…
48991	SEEN0703-295	dialogue	神奈	なぜ…なぜにみな、余だけを…残して…
49375	SEEN0703-679	dialogue	神奈	余も手伝おうぞ
38513	SEEN0603-323	dialogue	聖	うむ。良い選択だ
39978	SEEN0608-313	dialogue	聖	うむ。悩みがあるのなら、この綺麗なお姉さんに話してごらん
40352	SEEN0609-28	dialogue	往人	うむ。それが何かは、道々教えてやる
43987	SEEN0700-283	dialogue	神奈	うむ。わかれればよい
44110	SEEN0700-406	dialogue	神奈	うむ、大儀であった
44579	SEEN0700-876	dialogue	神奈	むーっ！ むむむっ！ むむむぐうむうむ……

# Cluster 1: 少女、声、観鈴、みちる、佳乃、女の子



## AIR: Casual Female Language

- **Pick** 15 lines randomly
- Usual schoolgirl conversation
- However, occurrences (よお, うん, ねー, ちゃう) are shared within the group – same author?

わたし (3.31, 402)	ちゃっ (3.06, 100)	っと (2.13, 78)	し (2.15, 135)	ね (2.71, 848)	うん (2.83, 485)
あたし (3.3, 78)	ちゃう (2.64, 68)	~ (2.54, 32)	に (3.34, 36)	よお (3.24, 234)	あ (2.07, 128)
うぬ (3.34, 57)	ね (2.61, 64)	でー (2.0, 9)	ばっかり (2.34, 7)	ちや (2.38, 30)	うーん (3.09, 98)
きみ (3.34, 12)	だあ (3.09, 38)	じやあ (2.43, 8)	じゃあ (3.34, 10)	ねえ (2.98, 185)	えっと (2.31, 92)
ふん (3.34, 7)	たー (3.08, 36)	にい (3.34, 5)	からあ (3.34, 6)	ねー (3.26, 133)	うんっ (3.34, 88)



fc2web.com

http://airfun.fc2web.com › staff :

### Keyスタッフ一覧 - Key-Tactics

イシカワタカシ職種：ライター。「AIR」でライターを勤めるも病気でリタイアしてしまう。噂では佳乃シナリオか美凪シナリオの前半を書いたらしい。その後、VA系列の ...



speaker	text
佳乃	あたしお金持ってるから、オゴりだよお
みちる	うんっ。けっこーなことだ。にやはは
観鈴	暑いねー
少女	ねっ、ポテト
観鈴	社会人～
みちる	じゃーね。みちるはここでおわかれで——す
観鈴	痛かったよね。でも、こうしたら痛いの飛んでくからね
少女	うんっ...
佳乃	えええーっ。行こうよお、きっと楽しいよお
佳乃	えっと...
観鈴	そうそう。わたしもそう思う。お母さん、惚れちゃうよね
観鈴	うん。一度だけ飲んだことあるの
少女	キミは？
佳乃	ふあっ。やっぱり最高にサワヤカでおいしいね～
観鈴	なんか、ほんとにオタマジャクシみたいになっちゃったね

## Cluster 2: 美凪、裏葉



# AIR: Formal and Polite Language



**Minagi 美凪:** schoolgirl, astronomy club leader, calm/mild

**Uraha 裏葉:** female court lady of Kanna 神奈, ancestor of Misuzu 観鈴

**In common:** desu/masu form, use of Keigo

**Uraha:** excessive use of Keigo

speaker	text
裏葉	しかしながら、神奈さまのお気持ちはよくわかります
美凪	…星は…出でていませんでした
裏葉	神奈さま、こちらならよく見えます
美凪	…実は私…こういうものを持ってます
美凪	…あまりに楽しいので…思わずこれを進呈
美凪	…着替えとかは持っていますし…
裏葉	生き残らねば…ならないのですか…
裏葉	いささか不作法ですが…
美凪	…私はみちるのお陰で、私でいた…
美凪	…わかりました
美凪	…はい…えっと
美凪	…どうかしましたか
裏葉	神奈さまの御為なら、この命ささげようとも惜しくはございません
美凪	…あ
裏葉	はい、ただいま

私 (5.92, 149) わたくし (9.56, 39) こちら (6.32, 15) どちら (4.86, 6)	です (7.58, 410) ます (8.4, 381) で (2.13, 220) まし (7.65, 167) ませ (8.51, 126)	など (4.21, 18) ばかり (2.04, 6) さえ (2.39, 5)	はい (7.05, 184) あ (2.08, 31) えっと (2.3, 29) とも (6.02, 8)	ながら (2.4, 13) さえ (9.3, 15)
---	--	--	---	-------------------------------



# AIR: Dialectal Language

Haruko 晴子: Misuzu 観鈴's aunt;  
single guardian of Misuzu 観鈴  
after the death of her mother;  
addicted to alcohol

Mother 母: Misuzu 観鈴's  
mother

**In common:** Osaka dialect

「せや」「なんや」「ねん」「へん」 –  
company location

**Still dialect? 「あんた」「ほな」「よし」**

あんた (4.78, 312)	や (6.05, 589)	や (5.92, 603)	で (2.24, 126)	わ (3.16, 186)	ん (3.89, 94)
なん (2.13, 157)	たら (2.23, 217)	なんか (2.54, 42)	て (3.45, 17)	ねん (5.84, 116)	ほな (6.3, 62)
うち (6.3, 26)	やろ (6.14, 160)	たって (3.43, 12)	ど (3.33, 9)	や (5.55, 82)	ええ (4.97, 45)
かん (6.3, 20)	へん (6.25, 139)	かー (4.72, 6)	い (4.35, 78)	さかい (6.3, 6)	よっしゃ (6.3, 20)
わらわ (3.5, 10)	せ (3.49, 101)	なん (6.3, 5)	さかい (6.3, 6)	なー (3.65, 77)	よし (2.38, 20)



speaker	text
母	あんたが一晩中寝んと、トランプしとる夢や...
女	カラスにさえかまつてもらわれへん...
晴子	当然や。あの子、誘えるかいな
女	ヒヨコの親はニワトリや。恐竜なんかにならへんのに
女	せやろ？
晴子	あんた、出でいく前に、今着てる服返しや
晴子	あの子な、なんでかひよこを恐竜の子供や、思い込んでたねん
母	応援されてるっ...なんやわからんけど、飲んでみよっ
晴子	ちゃんと立っとるな。よし、無事や
女	あほっ、あんたは後ろやつ
女	重いで。あんたが抱いとった頃から、ずいぶん時間経ったからな
晴子	ほなまあ、頑張って稼ぎや
晴子	なんや、弱いんかいな
母	それにな、その保育所に、あほな子がおるねん
晴子	それもなー、誰かと遊んでたんやなくて、一人でいて泣き出したっていうねん



# Conclusion

---

- In *AIR*,
  - Keyword “特徵語” from our method could be recognized as “Yakuwarigo” that represents characteristics of specific individuals and groups;
  - Different script authors might affect extracted Keywords;
  - Observed non-female language, casual female language, formal and polite female language, and dialectal language as clusters.



# Limitations

- Not analyzing the minor group ( $\text{CoS} < 0.5$ );
- Misclassification of morphemes (or granularity issue);
  - ふんだ → [ふん (Pron)][だ] X
- Not exhaustive analysis of all possible role languages;
- Michiru みちる has phrases like 「わふっ」「によわ」 not recognized by our system (confuses morpheme analyzer);
- Only analyzed AIR, not other media (e.g., anime) and series
  - Difficulty in anime speech diarization – speaker recognition given subtitle line and corresponding audio clip

speaker	text
みちる	ふんだ、もうあんたの相手なんかしてやんないっ
みちる	ふんだっ
みちる	ふんだっ、あんたなんか泣いちゃえっ
みちる	ふんだっ。あんたなんか、そこで泣いてろっ
みちる	ふんだっ。そんなこというなら、お金のかせぎかた、おしえてやんない
みちる	ふんだっ。やっぱり*B*Aなんかに、はなすんじゃなかった
みちる	ふ、ふんだっ。食べたかったら、かってに食べればいいよ



# Credits

---

麻子軒. (2019). 計量的アプローチによる役割語の分類と抽出の試み テレビゲーム『ドラゴンクエスト3』を例に. *計量国語学*, 32(2), 103-116.

国立国語研究所, The National Language Research Institute, n.d., Vocabulary survey of television broadcasts 2 : Vocabulary lists: 国立国語研究所.

Teshigawara, M., & Kinsui, S. (2011). Modern Japanese 'Role Language' (Yakuwarigo): fictionalised orality in Japanese literature and popular culture. *Sociolinguistic Studies*, 5(1), 37.

McCann, P. (2020). fugashi, a tool for tokenizing Japanese in python. arXiv preprint arXiv:2010.06858.

Ward Jr, J. H. (1963). Hierarchical grouping to optimize an objective function. *Journal of the American statistical association*, 58(301), 236-244.

AIR Homepage: <https://key.visualarts.gr.jp/product/air/>

AIR Wikipedia:  
[https://ja.wikipedia.org/wiki/AIR\\_\(%E3%82%B2%E3%83%BC%E3%83%A0\)](https://ja.wikipedia.org/wiki/AIR_(%E3%82%B2%E3%83%BC%E3%83%A0))

# Q&A



# Thank you

