

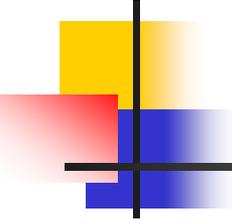
# リンク先ページの内容を反映させた Webページの特徴ベクトル改良法

---

奈良先端科学技術大学院大学

情報科学研究科

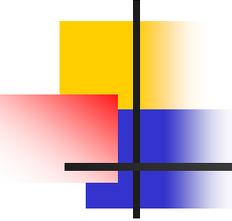
杉山一成 波多野賢治 吉川正俊 植村俊亮



# 発表の手順

---

- 本研究の目的
- 提案手法
- 評価実験・結果
- まとめ
- 今後の課題



# 本研究の目的

---

- Webページの検索

- 検索語の内容に関係のないページが多数提示される




より内容を考慮した索引付けが望まれる

- Webページの特徴

- ページ間にハイパーリンクによる内容的な結びつきがある



注目ページの近傍のページを含めた索引付けをする必要がある




# 本研究の目的(1)

---

- これまでの研究(DBWeb2001)
  - リンク先ページの内容を考慮した索引付け手法を提案(tf-idf法を改良)

## 問題点


- リンク先ページの扱い方について、検討不足
- 離れたリンク先に類似ページがある場合には、そのページの内容が反映されにくい
- 何リンク先のページまで扱えばよいか、検討不足



## 本研究の目的(2)

---

- リンク先ページの扱い方について、3つの特徴ベクトル改良手法を提案
- 各手法について、次の事項を検証
  - リンク先ページを考慮したことによるキーワード抽出精度
  - 改良特徴ベクトルを用いた検索精度の比較と、何リンク先までたどればよいか



## 3つの提案手法

---

ある注目しているWebページに対して、

(1) 個々のリンク先ページの内容を反映させる

(2) リンク先ページから構成される


クラスタの重心ベクトルを反映させる

(3) リンク先の各階層のWebページから構成される

クラスタの重心ベクトルを反映させる

# 提案手法(1)

各ページの内容を  
参照元ページに反映



# 各単語の重み付け(手法1)


注目ページ  $p_f$  の各単語  $t_k$  の重み

$$w_{t_k}^{p_f} = w_{t_k}^{p_f} + \sum_{i=1}^L \sum_{j=1}^{N_i} \frac{1}{dis(\mathbf{w}^{p_f}, \mathbf{w}^{p_{ij}})} w_{t_k}^{p_{ij}}$$

ただし、


$w_{t_k}^{p_f}$  : tf-idfによって求められた重み

$$dis(\mathbf{w}^{p_f}, \mathbf{w}^{p_{ij}}) = \sqrt{\sum_{k=1}^m (w_{t_k}^{p_f} - w_{t_k}^{p_{ij}})^2}$$



# 提案手法(2)

各群の重心ベクトルを  
参照元ページに反映



# 各単語の重み付け(手法2)


注目ページ  $p_f$  の各単語  $t_k$  の重み

$$w_{t_k}^{p_f} = w_{t_k}^{p_f} + \sum_{c=1}^K \frac{1}{dis(\mathbf{w}^{p_f}, \mathbf{w}^{g_c})} w_{t_k}^{g_c}$$

ただし、


$w_{t_k}^{p_f}$  : tf-idfによって求められた重み

$$dis(\mathbf{w}^{p_f}, \mathbf{w}^{g_c}) = \sqrt{\sum_{k=1}^m (w_{t_k}^{p_f} - w_{t_k}^{g_c})^2}$$



# 提案手法(3)

各階層でのクラスタリングで生成される重心ベクトルを参照元ページに反映



# 各単語の重み付け(手法3)


注目ページ  $p_f$  の各単語  $t_k$  の重み

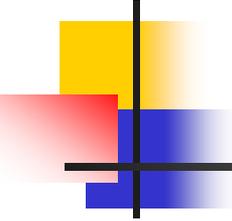
$$w_{t_k}^{p_f} = w_{t_k}^{p_f} + \sum_{i=1}^L \sum_{c=1}^K \frac{1}{dis(\mathbf{w}^{p_f}, \mathbf{w}^{g_{ic}})} w_{t_k}^{g_{ic}}$$

ただし、

$w_{t_k}^{p_f}$  : tf-idfによって求められた重み

$$dis(\mathbf{w}^{p_f}, \mathbf{w}^{g_{ic}}) = \sqrt{\sum_{k=1}^m (w_{t_k}^{p_f} - w_{t_k}^{g_{ic}})^2}$$





# 実験

---


## ■ 実験 1

- リンク先ページを考慮したことによるキーワード抽出精度の比較(スコアの高い上位10語までに、いくつかのキーワードが含まれるか)


## ■ 実験 2

- 改良した特徴ベクトルによる検索精度の比較


# 実験1 (手法1)



# 実験1 (手法2)




# 実験1 (手法3)




# 実験2 (手法1)

手法1と既存の検索エンジンの検索精度の比較




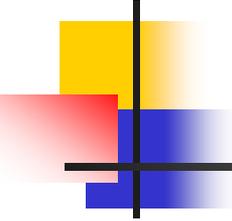
# 実験2 (手法2)



# 実験2 (手法3)

手法3と既存の検索エンジンとの比較

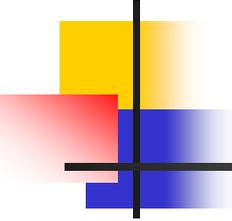




## まとめ

---

- tf-idf法によって作成した特徴ベクトルをリンク先ページを用いて改良する手法を提案
  - リンク先ページを使用することは、キーワード抽出や検索のための索引付けとして有効
  - Webページの内容は、そのページから2～3リンク先のWebページに集約されるといった知見が得られた。



# 今後の課題

---

- 個々のWebページのリンク環境に応じた特徴ベクトルの生成法についての検討、および検索精度の検証