

(19) 日本国特許庁(JP)

## (12) 特許公報(B2)

(11) 特許番号

特許第4010058号  
(P4010058)

(45) 発行日 平成19年11月21日(2007.11.21)

(24) 登録日 平成19年9月14日(2007.9.14)

(51) Int.CI.

F 1

G06F 17/30 (2006.01)

G06F 17/30 17OA  
G06F 17/30 419B

請求項の数 14 (全 27 頁)

(21) 出願番号	特願平10-222934	(73) 特許権者	000005496 富士ゼロックス株式会社 東京都港区赤坂九丁目7番3号
(22) 出願日	平成10年8月6日(1998.8.6)	(74) 代理人	100092152 弁理士 服部 毅巖
(65) 公開番号	特開2000-57152 (P2000-57152A)	(72) 発明者	沼田 賢一 神奈川県足柄上郡中井町境430 グリーンテクなかい 富士ゼロックス株式会社内
(43) 公開日	平成12年2月25日(2000.2.25)		
審査請求日	平成16年2月18日(2004.2.18)		
			審査官 深津 始
			(56) 参考文献 特開平07-325827 (JP, A) 特開平09-081580 (JP, A)
			(58) 調査した分野(Int.Cl., DB名) G06F 17/30

(54) 【発明の名称】文書関連付け装置、文書閲覧装置、文書関連付けプログラムを記録したコンピュータ読み取り可能な記録媒体及び文書閲覧プログラムを記録したコンピュータ読み取り可能な記録媒体

## (57) 【特許請求の範囲】

## 【請求項 1】

文書間の関連付けを行う文書関連付け装置において、  
属性が設定された複数の要素で構成され、文書識別子が設定された文書を複数格納する文書蓄積手段と、  
前記文書蓄積手段に格納されている複数の文書を被関連付け対象文書として順次選択し、選択した当該被関連付け対象文書中の要素のタグに対して、当該要素を一意に識別するための要素識別子を設定する識別子設定手段と、

前記識別子設定手段によって前記要素識別子が設定された前記被関連付け対象文書中の特定の属性を有する処理対象要素に含まれる内容からキーワードを抽出するキーワード抽出手段と、

前記キーワード抽出手段により抽出されたキーワードごとに、当該キーワードを含む、当該キーワードの抽出元となる前記被関連付け対象文書以外の文書を、前記文書蓄積手段内より検索する文書内容検索手段と、

前記文書内容検索手段により検索されたキーワードを含む文書ごとに、当該文書中の当該キーワードに対応付けられ、当該キーワードに関連する他の文書中の要素を示す属性値が複数登録可能なタグに、当該キーワードの抽出元となる前記被関連付け対象文書の文書識別子と、当該被関連付け対象文書内の当該キーワードを含む前記処理対象要素の要素識別子との組からなる属性値を複数設定するキーワード関連付け手段と、

を有することを特徴とする文書関連付け装置。

10

20

**【請求項 2】**

前記キーワード抽出手段は、前記被関連付け対象文書の表題としての属性を有する要素と、記載内容の見出しとしての属性を有する要素とを、前記処理対象要素として取り扱うことを特徴とする請求項1記載の文書関連付け装置。

**【請求項 3】**

構造化文書の内容を閲覧する文書閲覧装置において、  
属性が設定された複数の要素で構成され、文書識別子が設定された文書を複数格納する文書蓄積手段と、  
前記文書蓄積手段に格納されている複数の文書を被関連付け対象文書として順次選択し、選択した当該被関連付け対象文書中の要素のタグに対して、当該要素を一意に識別するための要素識別子を設定する識別子設定手段と、 10  
前記識別子設定手段によって前記要素識別子が設定された前記被関連付け対象文書中の特定の属性を有する処理対象要素に含まれる内容からキーワードを抽出するキーワード抽出手段と、

前記キーワード抽出手段により抽出されたキーワードごとに、当該キーワードを含む、当該キーワードの抽出元となる前記被関連付け対象文書以外の文書を、前記文書蓄積手段内より検索する文書内容検索手段と、

前記文書内容検索手段により検索されたキーワードを含む文書ごとに、当該文書中の当該キーワードに対応付けられ、当該キーワードに関連する他の文書中の要素を示す属性値が複数登録可能なタグに、当該キーワードの抽出元となる前記被関連付け対象文書の文書識別子と、当該被関連付け対象文書内の当該キーワードを含む前記処理対象要素の要素識別子との組からなる属性値を複数設定するキーワード関連付け手段と、 20

文書閲覧要求に応じて、当該文書閲覧要求で指定された文書を前記文書蓄積手段から抽出し、表示する文書表示手段と、

操作入力により、前記文書表示手段にて表示された文書中で、他の文書中の要素を示す1つ以上の属性値が登録されたタグを有する前記キーワードが選択されると、当該キーワードのタグに設定された属性値に基づいて、当該キーワードに関連する前記被関連付け対象文書中の処理対象要素を抽出する要素抽出手段と、

前記要素抽出手段により抽出された前記処理対象要素の内容を表示する内容表示手段と、 30  
を有することを特徴とする文書閲覧装置。

**【請求項 4】**

構造化文書の内容を閲覧する文書閲覧装置において、  
属性が設定された複数の要素による階層的な論理構造が形成されており、文書識別子が設定された文書を複数格納する文書蓄積手段と、

前記文書蓄積手段に格納されている複数の文書を被関連付け対象文書として順次選択し、選択した当該被関連付け対象文書中の要素のタグに対して、当該要素を一意に識別するための要素識別子を設定し、当該被関連付け対象文書の階層構造における上位構造の要素のタグに対して、下位構造の要素の要素識別子を設定する階層構造関連付け手段と、

前記階層構造関連付け手段によって前記要素識別子が設定された前記被関連付け対象文書中の特定の属性を有する処理対象要素に含まれる内容から、キーワードを抽出するキーワード抽出手段と、 40  
前記キーワード抽出手段により抽出されたキーワードごとに、当該キーワードを含む、当該キーワードの抽出元となる前記被関連付け対象文書以外の文書を、前記文書蓄積手段内より検索する文書内容検索手段と、

前記文書内容検索手段により検索されたキーワードを含む文書ごとに、当該文書中の当該キーワードに対応付けられ、当該キーワードに関連する他の文書中の要素を示す属性値が複数登録可能なタグに、当該キーワードの抽出元となる前記被関連付け対象文書の文書識別子と、当該被関連付け対象文書内の当該キーワードを含む前記処理対象要素の要素識別子との組からなる属性値を複数設定するキーワード関連付け手段と、 50

文書閲覧要求に応じて、当該文書閲覧要求で指定された文書を前記文書蓄積手段から抽出し、表示する文書表示手段と、

操作入力により、前記文書表示手段にて表示された文書中で、他の文書中の要素を示す1つ以上の属性値が登録されたタグを有する前記キーワードが選択されると、当該キーワードのタグに設定された属性値に基づいて、当該キーワードに関連する前記被関連付け対象文書中の処理対象要素を抽出すると共に、抽出した前記処理対象要素のタグに設定された要素識別子に基づいて、当該処理対象要素の下位構造の要素を順次抽出する要素抽出手段と、

前記要素抽出手段により抽出された前記処理対象要素の内容及び前記処理対象要素に関連付けられている下位の要素の内容を表示する内容表示手段と、

を有することを特徴とする文書閲覧装置。

#### 【請求項 5】

前記要素抽出手段は、選択されたキーワードのタグに複数の属性値が設定されており、当該属性値に基づいて複数の処理対象要素が抽出された場合には、前記内容表示手段によって表示された複数の処理対象要素のうちの1つを選択する操作入力を受け付け、選択された処理対象要素に関してのみ、下位構造の要素を抽出し、下位構造の要素が複数抽出された場合には、前記内容表示手段によって表示された複数の下位構造の要素のうちの1つを選択する操作入力を受け付け、選択された下位構造の要素に関してのみ、さらに下位構造の要素の抽出を行う、

ことを特徴とする請求項4記載の文書閲覧装置。

#### 【請求項 6】

前記要素抽出手段は、選択されたキーワードのタグに複数の属性値が設定されている場合、各属性値に含まれる文書識別子によって、当該属性値に対応する処理対象要素が含まれる文書を判断し、同一の文書に含まれる複数の処理対象要素を同じグループにグループ化し、同じグループに属する複数の処理対象要素が連続するように処理対象要素を並べ、

前記文書表示手段は、前記要素抽出手段で並べられた順に前記処理対象要素の内容を表示することを特徴とする請求項4記載の文書閲覧装置。

#### 【請求項 7】

前記要素抽出手段は、前記処理対象要素をグループ化した場合には、グループに属する処理対象要素の数、およびグループに属する処理対象要素の文書内論理構造上の階層の深さに基づいて、各グループの重要度を算出し、各グループの重要度に応じてグループを並べ替えることを特徴とする請求項6記載の文書閲覧装置。

#### 【請求項 8】

前記要素抽出手段は、文書ごとにグループ化された処理対象要素を、処理対象要素の論理構造における階層の深さおよび文書中での出現順序に応じてグループ内で並べ替えることを特徴とする請求項6記載の文書閲覧装置。

#### 【請求項 9】

文書間の関連付けを行うための文書関連付けプログラムを記録したコンピュータ読み取り可能な記録媒体において、

属性が設定された複数の要素で構成され、文書識別子が設定された文書を複数格納する文書蓄積手段、

前記文書蓄積手段に格納されている複数の文書を被関連付け対象文書として順次選択し、選択した当該被関連付け対象文書中の要素のタグに対して、当該要素を一意に識別するための要素識別子を設定する識別子設定手段、

前記識別子設定手段によって前記要素識別子が設定された前記被関連付け対象文書中の特定の属性を有する処理対象要素に含まれる内容からキーワードを抽出するキーワード抽出手段、

前記キーワード抽出手段により抽出されたキーワードごとに、当該キーワードを含む、当該キーワードの抽出元となる前記被関連付け対象文書以外の文書を、前記文書蓄積手段内より検索する文書内容検索手段、

10

20

30

40

50

前記文書内容検索手段により検索されたキーワードを含む文書ごとに、当該文書中の当該キーワードに対応付けられ、当該キーワードに関連する他の文書中の要素を示す属性値が複数登録可能なタグに、当該キーワードの抽出元となる前記被関連付け対象文書の文書識別子と、当該被関連付け対象文書内の当該キーワードを含む前記処理対象要素の要素識別子との組からなる属性値を複数設定するキーワード関連付け手段、

としてコンピュータを機能させることを特徴とする文書関連付けプログラムを記録したコンピュータ読み取り可能な記録媒体。

#### 【請求項10】

構造化文書の内容を閲覧するための文書閲覧プログラムを記録したコンピュータ読み取り可能な記録媒体において、

コンピュータを、

属性が設定された複数の要素で構成され、文書識別子が設定された文書を複数格納する文書蓄積手段、

前記文書蓄積手段に格納されている複数の文書を被関連付け対象文書として順次選択し、選択した当該被関連付け対象文書中の要素のタグに対して、当該要素を一意に識別するための要素識別子を設定する識別子設定手段、

前記識別子設定手段によって前記要素識別子が設定された前記被関連付け対象文書中の特定の属性を有する処理対象要素に含まれる内容からキーワードを抽出するキーワード抽出手段、

前記キーワード抽出手段により抽出されたキーワードごとに、当該キーワードを含む、当該キーワードの抽出元となる前記被関連付け対象文書以外の文書を、前記文書蓄積手段内より検索する文書内容検索手段、

前記文書内容検索手段により検索されたキーワードを含む文書ごとに、当該文書中の当該キーワードに対応付けられ、当該キーワードに関連する他の文書中の要素を示す属性値が複数登録可能なタグに、当該キーワードの抽出元となる前記被関連付け対象文書の文書識別子と、当該被関連付け対象文書内の当該キーワードを含む前記処理対象要素の要素識別子との組からなる属性値を複数設定するキーワード関連付け手段、

文書閲覧要求に応じて、当該文書閲覧要求で指定された文書を前記文書蓄積手段から抽出し、表示する文書表示手段、

操作入力により、前記文書表示手段にて表示された文書中で、他の文書中の要素を示す1つ以上の属性値が登録されたタグを有する前記キーワードが選択されると、当該キーワードのタグに設定された属性値に基づいて、当該キーワードに関連する前記被関連付け対象文書中の処理対象要素を抽出する要素抽出手段、

前記要素抽出手段により抽出された前記処理対象要素の内容を表示する内容表示手段、

として機能させることを特徴とする文書閲覧プログラムを記録したコンピュータ読み取り可能な記録媒体。

#### 【請求項11】

構造化文書の内容を閲覧するための文書閲覧プログラムを記録したコンピュータ読み取り可能な記録媒体において、

コンピュータを、

属性が設定された複数の要素による階層的な論理構造が形成されており、文書識別子が設定された文書を複数格納する文書蓄積手段、

前記文書蓄積手段に格納されている複数の文書を被関連付け対象文書として順次選択し、選択した当該被関連付け対象文書中の要素のタグに対して、当該要素を一意に識別するための要素識別子を設定し、当該被関連付け対象文書の階層構造における上位構造の要素のタグに対して、下位構造の要素の要素識別子を設定する階層構造関連付け手段、

前記階層構造関連付け手段によって前記要素識別子が設定された前記被関連付け対象文書中の特定の属性を有する処理対象要素に含まれる内容から、キーワードを抽出するキーワード抽出手段、

前記キーワード抽出手段により抽出されたキーワードごとに、当該キーワードを含む、

10

20

30

40

50

当該キーワードの抽出元となる前記被関連付け対象文書以外の文書を、前記文書蓄積手段内より検索する文書内容検索手段、

前記文書内容検索手段により検索されたキーワードを含む文書ごとに、当該文書中の当該キーワードに対応付けられ、当該キーワードに関連する他の文書中の要素を示す属性値が複数登録可能なタグに、当該キーワードの抽出元となる前記被関連付け対象文書の文書識別子と、当該被関連付け対象文書内の当該キーワードを含む前記処理対象要素の要素識別子との組からなる属性値を複数設定するキーワード関連付け手段、

文書閲覧要求に応じて、当該文書閲覧要求で指定された文書を前記文書蓄積手段から抽出し、表示する文書表示手段、

操作入力により、前記文書表示手段にて表示された文書中で、他の文書中の要素を示す1つ以上の属性値が登録されたタグを有する前記キーワードが選択されると、当該キーワードのタグに設定された属性値に基づいて、当該キーワードに関連する前記被関連付け対象文書中の処理対象要素を抽出すると共に、抽出した前記処理対象要素のタグに設定された要素識別子に基づいて、当該処理対象要素の下位構造の要素を順次抽出する要素抽出手段、

前記要素抽出手段により抽出された前記処理対象要素の内容及び前記処理対象要素に関連付けられている下位の要素の内容を表示する内容表示手段、

として機能させることを特徴とする文書閲覧プログラムを記録したコンピュータ読み取り可能な記録媒体。

#### 【請求項 1 2】

文書間の関連付けを行うための文書関連付け方法において、

文書蓄積手段が、属性が設定された複数の要素で構成され、文書識別子が設定された文書を複数格納し、

識別子設定手段が、前記文書蓄積手段に格納されている複数の文書を被関連付け対象文書として順次選択し、選択した当該被関連付け対象文書中の要素のタグに対して、当該要素を一意に識別するための要素識別子を設定し、

キーワード抽出手段が、前記識別子設定手段によって前記要素識別子が設定された前記被関連付け対象文書中の特定の属性を有する処理対象要素に含まれる内容からキーワードを抽出し、

文書内容検索手段が、前記キーワード抽出手段により抽出されたキーワードごとに、当該キーワードを含む、当該キーワードの抽出元となる前記被関連付け対象文書以外の文書を、前記文書蓄積手段内より検索し、

キーワード関連付け手段が、前記文書内容検索手段により検索されたキーワードを含む文書ごとに、当該文書中の当該キーワードに対応付けられ、当該キーワードに関連する他の文書中の要素を示す属性値が複数登録可能なタグに、当該キーワードの抽出元となる前記被関連付け対象文書の文書識別子と、当該被関連付け対象文書内の当該キーワードを含む前記処理対象要素の要素識別子との組からなる属性値を複数設定する、

ことを特徴とする文書関連付け方法。

#### 【請求項 1 3】

構造化文書の内容を閲覧するための文書閲覧方法において、

文書蓄積手段が、属性が設定された複数の要素で構成され、文書識別子が設定された文書を複数格納し、

識別子設定手段が、前記文書蓄積手段に格納されている複数の文書を被関連付け対象文書として順次選択し、選択した当該被関連付け対象文書中の要素のタグに対して、当該要素を一意に識別するための要素識別子を設定し、

キーワード抽出手段が、前記識別子設定手段によって前記要素識別子が設定された前記被関連付け対象文書中の特定の属性を有する処理対象要素に含まれる内容からキーワードを抽出し、

文書内容検索手段が、前記キーワード抽出手段により抽出されたキーワードごとに、当該キーワードを含む、当該キーワードの抽出元となる前記被関連付け対象文書以外の文書

10

20

30

40

50

を、前記文書蓄積手段内より検索し、

キーワード関連付け手段が、前記文書内容検索手段により検索されたキーワードを含む文書ごとに、当該文書中の当該キーワードに対応付けられ、当該キーワードに関連する他の文書中の要素を示す属性値が複数登録可能なタグに、当該キーワードの抽出元となる前記被関連付け対象文書の文書識別子と、当該被関連付け対象文書内の当該キーワードを含む前記処理対象要素の要素識別子との組からなる属性値を複数設定し、

文書表示手段が、文書閲覧要求に応じて、当該文書閲覧要求で指定された文書を前記文書蓄積手段から抽出し、表示し、

要素抽出手段が、操作入力により、前記文書表示手段にて表示された文書中で、他の文書中の要素を示す1つ以上の属性値が登録されたタグを有する前記キーワードが選択されると、当該キーワードのタグに設定された属性値に基づいて、当該キーワードに関連する前記被関連付け対象文書中の処理対象要素を抽出し、

内容表示手段が、前記要素抽出手段により抽出された前記処理対象要素の内容を表示する、

ことを特徴とする文書閲覧方法。

#### 【請求項14】

構造化文書の内容を閲覧するための文書閲覧方法において、

文書蓄積手段が、属性が設定された複数の要素による階層的な論理構造が形成されており、文書識別子が設定された文書を複数格納し、

階層構造関連付け手段が、前記文書蓄積手段に格納されている複数の文書を被関連付け対象文書として順次選択し、選択した当該被関連付け対象文書中の要素のタグに対して、当該要素を一意に識別するための要素識別子を設定し、当該被関連付け対象文書の階層構造における上位構造の要素のタグに対して、下位構造の要素の要素識別子を設定し、

キーワード抽出手段が、前記階層構造関連付け手段によって前記要素識別子が設定された前記被関連付け対象文書中の特定の属性を有する処理対象要素に含まれる内容から、キーワードを抽出し、

文書内容検索手段が、前記キーワード抽出手段により抽出されたキーワードごとに、当該キーワードを含む、当該キーワードの抽出元となる前記被関連付け対象文書以外の文書を、前記文書蓄積手段内より検索し、

キーワード関連付け手段が、前記文書内容検索手段により検索されたキーワードを含む文書ごとに、当該文書中の当該キーワードに対応付けられ、当該キーワードに関連する他の文書中の要素を示す属性値が複数登録可能なタグに、当該キーワードの抽出元となる前記被関連付け対象文書の文書識別子と、当該被関連付け対象文書内の当該キーワードを含む前記処理対象要素の要素識別子との組からなる属性値を複数設定し、

文書表示手段が、文書閲覧要求に応じて、当該文書閲覧要求で指定された文書を前記文書蓄積手段から抽出し、表示し、

要素抽出手段が、操作入力により、前記文書表示手段にて表示された文書中で、他の文書中の要素を示す1つ以上の属性値が登録されたタグを有する前記キーワードが選択されると、当該キーワードのタグに設定された属性値に基づいて、当該キーワードに関連する前記被関連付け対象文書中の処理対象要素を抽出すると共に、抽出した前記処理対象要素のタグに設定された要素識別子に基づいて、当該処理対象要素の下位構造の要素を順次抽出し、

内容表示手段が、前記要素抽出手段により抽出された前記処理対象要素の内容及び前記処理対象要素に関連付けられている下位の要素の内容を表示する、

ことを特徴とする文書閲覧方法。

#### 【発明の詳細な説明】

##### 【0001】

##### 【発明の属する技術分野】

本発明は文書関連付け装置、文書閲覧装置、文書関連付けプログラムを記録したコンピュータ読み取り可能な記録媒体、及び文書閲覧プログラムを記録したコンピュータ読み取り

10

20

30

40

50

可能な記録媒体に関し、特に文書中のあるキーワードとそのキーワードに関連する他の文書の内容を関連付ける文書関連付け装置、文書中のあるキーワードとそのキーワードに関連する他の文書の内容とが関連付けられた文書群中の文書を閲覧する文書閲覧装置、前記文書関連付け装置をコンピュータ上で実現するための文書関連付けプログラムを記録したコンピュータ読み取り可能な記録媒体、及び前記文書閲覧装置をコンピュータ上で実現するための文書閲覧プログラムを記録したコンピュータ読み取り可能な記録媒体に関する。

#### 【0002】

##### 【従来の技術】

ネットワーク上に散在する電子文書群をリンクによって関連付けることが可能な、いわゆるハイパーテキストシステムが、World Wide Web(WWW)の普及により、一般に広く利用されるようになってきている。ハイパーテキストシステムでは、ある文書中のキーワードに対して、より詳しい情報を持つ他の文書の内容へのハイパーリンクを付与しておく。これによって、利用者がその文書を閲覧していて、ハイパーリンクが付与された記述についてより詳しく知りたいと思ったときには、そのハイパーリンクを辿ることによって関連情報を知ることができる。

#### 【0003】

ところが、一般的にこのようなハイパーテキスト文書を作成するためには、文書の作成者が手作業でキーワードと他の文書との関連付けを行ってハイパーリンクを作成する必要があり、多大の労力と時間を要する。そこで、この問題を解決するために、文書中のキーワードを自動抽出して、他の文書から同一または同義のキーワードを含むものを検索することによって、文書間の関連付けすなわちハイパーリンクを自動的に作成することが考えられている。

#### 【0004】

このとき単純に同一または同義のキーワードを手がかりとして文書を関連付けるだけでは、ハイパーリンクを辿ることによって、より詳しい説明が得られるという保証がない。なぜならば、関連付けられた文書のいずれにおいても同一または同義のキーワードが一言参照されているだけでそのキーワードの説明に当たる記述がない場合が往々にしてあり得るからである。

#### 【0005】

この問題を解決する1つの方法として、特開平5-20362号公報に開示された「文書テキスト間の連鎖自動作成システム」がある。この公報に開示された方法では、まず、文書テキストから重要キーワードを抽出し、抽出したキーワードの文書における重要度を算出する。その上で、同一のキーワードを共有する文書どうして、キーワードの重要度の低い方の文書からキーワードの重要度の高い方の文書への、單方向の関連付けを自動生成する。この方法では、同一のキーワードを手がかりとして文書を関連付けているが、同一キーワードの文書における重要度の高い文書のほうが、重要度の低い文書よりも、そのキーワードに関してより詳しい説明されているものと仮定している。これによって、文書中のあるキーワードから、より詳しい説明が記述された他の文書に対するハイパーリンクが自動的に生成される。以下のこの方法を第1の従来技術とする。

#### 【0006】

また、上記問題を解決する別の方法として特開平7-325827号公報に開示された「ハイパーテキスト自動生成装置」がある。この公報には、同一または同義のキーワードを持つ文書どうしを関連付ける際に、一方の文書のキーワードから、他の文書の同一または同義のキーワードを持つ章や節の見出しに対してハイパーリンクを生成する方法が示されている。この方法では、あるキーワードが見出しに含まれる場合、見出し以下の内容において、そのキーワードについて詳しく述べている可能性が高いと仮定している。これによって、文書中のあるキーワードから、より詳しい説明に対するハイパーリンクが自動的に生成される。以下のこの方法を第2の従来技術とする。

#### 【0007】

##### 【発明が解決しようとする課題】

10

20

30

40

50

しかし、いずれの従来技術においても、以下のような問題点があった。

第1の従来技術では、関連付けの対象はある文書中のキーワードと他の文書全体である。そのため、関連付けられる他の文書の記述量が多い場合には、たとえ関連付けられたキーワードに対する詳しい説明が文書中に記述されていたとしても、文書中で関連する記述を見つけ出すことが困難である。

#### 【0008】

第2の従来技術では、ある文書中のキーワードに対して、同一または同義のキーワードが含まれる他の文書が複数存在する場合には、予め与えられた戦略に従って候補をいずれか1つに絞るようになっている。そのため、利用者が実際に知りたい情報が関連付けの対象から洩れてしまうおそれがある。なお、この問題については、例えば関連付けの対象となる候補が複数存在する場合にその候補全てを関連付けてしまうことによって洩れを防ぐことができる。しかし、この場合には、利用者が複数の関連付けられた記述を順次閲覧し、必要な情報を探すという手間がかかる。

#### 【0009】

さらに、上記2つの従来技術のいずれにおいても、関連付けの対象となるキーワードを自動抽出するために、文書全体に対して形態素解析を行う必要がある。形態素解析を高精度に行うには、かなり複雑な処理を行わなければならない。そのため、従来の技術を用いて大量の文書間のハイパーアリンクを自動作成するには、処理に非常に時間がかかるという問題点があった。

#### 【0010】

本発明はこのような点に鑑みてなされたものであり、文書中のキーワードを他の文書中の最小限の関連記述に関連付ける処理を高速に行うことができる文書関連付け装置を提供することを目的とする。

#### 【0011】

また、本発明の第2の目的は、文書中のキーワードを他の文書中の最小限の関連記述に関連付けられた文書群内の文書を閲覧するための文書閲覧装置を提供することである。

#### 【0012】

また、本発明の第3の目的は、文書中のキーワードを他の文書中の最小限の関連記述に関連付ける処理をコンピュータに高速に行わせることができる文書関連付けプログラムを記録したコンピュータ読み取り可能な記録媒体を提供することである。

#### 【0013】

また、本発明の第4の目的は、文書中のキーワードを他の文書中の最小限の関連記述に関連付けられた文書群内の文書をコンピュータを用いて閲覧するための文書閲覧プログラムを記録したコンピュータ読み取り可能な記録媒体を提供することである。

#### 【0014】

##### 【課題を解決するための手段】

本発明では上記課題を解決するために、文書間の関連付けを行う文書関連付け装置において、属性が設定された複数の要素で構成され、文書識別子が設定された文書を複数格納する文書蓄積手段と、前記文書蓄積手段に格納されている複数の文書を被関連付け対象文書として順次選択し、選択した当該被関連付け対象文書中の要素のタグに対して、当該要素を一意に識別するための要素識別子を設定する識別子設定手段と、前記識別子設定手段によって前記要素識別子が設定された前記被関連付け対象文書中の特定の属性を有する処理対象要素に含まれる内容からキーワードを抽出するキーワード抽出手段と、前記キーワード抽出手段により抽出されたキーワードごとに、当該キーワードを含む、当該キーワードの抽出元となる前記被関連付け対象文書以外の文書を、前記文書蓄積手段内より検索する文書内容検索手段と、前記文書内容検索手段により検索されたキーワードを含む文書ごとに、当該文書中の当該キーワードに対応付けられ、当該キーワードに関連する他の文書中の要素を示す属性値が複数登録可能なタグに、当該キーワードの抽出元となる前記被関連付け対象文書の文書識別子と、当該被関連付け対象文書内の当該キーワードを含む前記処理対象要素の要素識別子との組からなる属性値を複数設定するキーワード関連付け手段

10

20

30

40

50

と、を有することを特徴とする文書関連付け装置が提供される。

#### 【0015】

このような文書関連付け装置によれば、階層構造関連付け手段により、前記文書蓄積手段に格納されている文書が被関連付け対象文書とされ、被関連付け対象文書中の要素のタグに対して、その要素を一意に識別するための要素識別子が設定される。また、キーワード抽出手段により、被関連付け対象文書中の特定の属性を有する処理対象要素に含まれる内容からキーワードが抽出される。すると、文書内容検索手段により、キーワード抽出手段が抽出したキーワードを含む文書が文書蓄積手段内から検索される。そして、キーワード関連付け手段により、文書内容検索手段により検索された文書中のキーワードの複数登録可能なタグに、キーワードの抽出元となる被関連付け対象文書の文書識別子と、被関連付け対象文書内のキーワードを含む処理対象要素の要素識別子との組からなる属性値が複数設定される。10

#### 【0016】

また上記課題を解決するために、構造化文書の内容を閲覧する文書閲覧装置において、属性が設定された複数の要素で構成され、文書識別子が設定された文書を複数格納する文書蓄積手段と、前記文書蓄積手段に格納されている複数の文書を被関連付け対象文書として順次選択し、選択した当該被関連付け対象文書中の要素のタグに対して、当該要素を一意に識別するための要素識別子を設定する識別子設定手段と、前記識別子設定手段によつて前記要素識別子が設定された前記被関連付け対象文書中の特定の属性を有する処理対象要素に含まれる内容からキーワードを抽出するキーワード抽出手段と、前記キーワード抽出手段により抽出されたキーワードごとに、当該キーワードを含む、当該キーワードの抽出元となる前記被関連付け対象文書以外の文書を、前記文書蓄積手段内より検索する文書内容検索手段と、前記文書内容検索手段により検索されたキーワードを含む文書ごとに、当該文書中の当該キーワードに対応付けられ、当該キーワードに関連する他の文書中の要素を示す属性値が複数登録可能なタグに、当該キーワードの抽出元となる前記被関連付け対象文書の文書識別子と、当該被関連付け対象文書内の当該キーワードを含む前記処理対象要素の要素識別子との組からなる属性値を複数設定するキーワード関連付け手段と、文書閲覧要求に応じて、当該文書閲覧要求で指定された文書を前記文書蓄積手段から抽出し、表示する文書表示手段と、操作入力により、前記文書表示手段にて表示された文書中で、他の文書中の要素を示す1つ以上の属性値が登録されたタグを有する前記キーワードが選択されると、当該キーワードのタグに設定された属性値に基づいて、当該キーワードに関連する前記被関連付け対象文書中の処理対象要素を抽出する要素抽出手段と、前記要素抽出手段により抽出された前記処理対象要素の内容を表示する内容表示手段と、を有することを特徴とする文書閲覧装置が提供される。20

#### 【0017】

このような文書閲覧装置によれば、階層構造関連付け手段により、前記文書蓄積手段に格納されている文書が被関連付け対象文書とされ、被関連付け対象文書中の要素のタグに対して、その要素を一意に識別するための要素識別子が設定される。また、キーワード抽出手段により、被関連付け対象文書中の特定の属性を有する処理対象要素に含まれる内容からキーワードが抽出される。すると、文書内容検索手段により、キーワード抽出手段が抽出したキーワードを含む文書が文書蓄積手段内から検索される。そして、キーワード関連付け手段により、文書内容検索手段により検索された文書中のキーワードの複数登録可能なタグに、キーワードの抽出元となる被関連付け対象文書の文書識別子と、被関連付け対象文書内のキーワードを含む処理対象要素の要素識別子との組からなる属性値が複数設定される。さらに、文書閲覧要求が入力されると、文書表示手段により、文書閲覧要求に応じた文書が文書蓄積手段から抽出される。この文書表示手段にて抽出された文書中で、キーワード関連付け手段により関連付けられたキーワードが選択されると、要素抽出手段により、キーワードに対して関連付けられた1又は複数の被関連付け対象文書中の関連要素が抽出される。40

#### 【0018】

10

20

30

40

50

さらに、内容表示手段により、前記要素抽出手段により抽出された前記関連要素の内容が抽出され、表示される。

また上記課題を解決するために、文書間の関連付けを行うための文書関連付けプログラムを記録したコンピュータ読み取り可能な記録媒体において、属性が設定された複数の要素で構成され、文書識別子が設定された文書を複数格納する文書蓄積手段、前記文書蓄積手段に格納されている複数の文書を被関連付け対象文書として順次選択し、選択した当該被関連付け対象文書中の要素のタグに対して、当該要素を一意に識別するための要素識別子を設定する要素識別子設定手段、前記要素識別子設定手段によって前記要素識別子が設定された前記被関連付け対象文書中の特定の属性を有する処理対象要素に含まれる内容からキーワードを抽出するキーワード抽出手段、前記キーワード抽出手段により抽出されたキーワードごとに、当該キーワードを含む、当該キーワードの抽出元となる前記被関連付け対象文書以外の文書を、前記文書蓄積手段内より検索する文書内容検索手段、前記文書内容検索手段により検索されたキーワードを含む文書ごとに、当該文書中の当該キーワードに対応付けられ、当該キーワードに関連する他の文書中の要素を示す属性値が複数登録可能なタグに、当該キーワードの抽出元となる前記被関連付け対象文書の文書識別子と、当該被関連付け対象文書内の当該キーワードを含む前記処理対象要素の要素識別子との組からなる属性値を複数設定するキーワード関連付け手段、としてコンピュータを機能させることを特徴とする文書関連付けプログラムを記録したコンピュータ読み取り可能な記録媒体が提供される。10

#### 【0019】

この記録媒体に記録された文書関連付けプログラムをコンピュータに実行させれば、上記本発明に係る文書関連付け装置の機能がコンピュータ上に構築される。20

#### 【0020】

また上記課題を解決するために、構造化文書の内容を閲覧するための文書閲覧プログラムを記録したコンピュータ読み取り可能な記録媒体において、コンピュータを、属性が設定された複数の要素で構成され、文書識別子が設定された文書を複数格納する文書蓄積手段、前記文書蓄積手段に格納されている複数の文書を被関連付け対象文書として順次選択し、選択した当該被関連付け対象文書中の要素のタグに対して、当該要素を一意に識別するための要素識別子を設定する要素識別子設定手段、前記要素識別子設定手段によって前記要素識別子が設定された前記被関連付け対象文書中の特定の属性を有する処理対象要素に含まれる内容からキーワードを抽出するキーワード抽出手段、前記キーワード抽出手段により抽出されたキーワードごとに、当該キーワードを含む、当該キーワードの抽出元となる前記被関連付け対象文書以外の文書を、前記文書蓄積手段内より検索する文書内容検索手段、前記文書内容検索手段により検索されたキーワードを含む文書ごとに、当該文書中の当該キーワードに対応付けられ、当該キーワードに関連する他の文書中の要素を示す属性値が複数登録可能なタグに、当該キーワードの抽出元となる前記被関連付け対象文書の文書識別子と、当該被関連付け対象文書内の当該キーワードを含む前記処理対象要素の要素識別子との組からなる属性値を複数設定するキーワード関連付け手段、文書閲覧要求に応じて、当該文書閲覧要求で指定された文書を前記文書蓄積手段から抽出し、表示する文書表示手段、操作入力により、前記文書表示手段にて表示された文書中で、他の文書中の要素を示す1つ以上の属性値が登録されたタグを有する前記キーワードが選択されると、当該キーワードのタグに設定された属性値に基づいて、当該キーワードに関連する前記被関連付け対象文書中の処理対象要素を抽出する要素抽出手段、前記要素抽出手段により抽出された前記処理対象要素の内容を表示する内容表示手段、として機能させることを特徴とする文書閲覧プログラムを記録したコンピュータ読み取り可能な記録媒体が提供される。30

#### 【0021】

この記録媒体に記録された文書閲覧プログラムをコンピュータに実行させれば、上記本発明に係る文書閲覧装置の機能がコンピュータ上に構築される。40

#### 【0022】

#### 【発明の実施の形態】

以下、本発明の実施の形態を図面を参照して説明する。

図1は、本発明の原理構成図である。本発明の文書関連付け装置は、以下の要素で構成される。

#### 【0023】

文書蓄積手段1は、階層的な論理構造の文書群を蓄積する。構造化された文書としては、SGMLの規定に従って作成された文書などがある。

階層構造関連付け手段2は、文書蓄積手段1から被関連付け対象文書2aを読み込み、読み込んだ被関連付け対象文書2aを構成する各要素の上位構造と下位構造とを関連付ける。例えば、各要素に識別子を与える。そして、各要素に対して、その要素の下位構造となる要素の識別子の情報を持たせる。要素間の関連付けを行った被関連付け対象文書2aは10、文書蓄積手段1に戻す。

#### 【0024】

キーワード抽出手段3は、被関連付け対象文書2a中の特定の属性を有する処理対象要素に含まれる内容からキーワードを抽出する。例えば、表題としての属性を有する要素と、見出しとしての属性を有する要素とを、処理対象要素とする。すると、キーワード抽出手段3は、抽出元の要素の識別子と、その要素から抽出されたキーワードの集合とを対応づけたキーワード対応表3aを内部で生成する。そして、被関連付け対象文書2aに関するキーワード対応表3aを文書内容検索手段4に渡す。

#### 【0025】

文書内容検索手段4は、キーワード抽出手段3により抽出されたキーワードに基づいて、文書蓄積手段1に蓄積されている他の文書の内容を検索する。見つけ出した文書4aは、キーワード関連付け手段5に渡す。20

#### 【0026】

キーワード関連付け手段5は、文書内容検索手段4により検出された文書4aの内容中のキーワードと、キーワードの抽出元となる被関連付け対象文書2aの処理対象要素とを関連付ける。被関連付け対象文書2aの特定の要素への関連付けを行った文書5aは、文書蓄積手段1に格納する。

#### 【0027】

このような文書関連付け装置によれば、階層構造関連付け手段2に読み込まれた被関連付け対象文書2aは、各要素の上位構造と下位構造との関連付けが行われ、文書蓄積手段1に戻される。このとき、キーワード抽出手段3により、各要素の内容の中からキーワードが抽出される。すると、文書内容検索手段4により、抽出されたキーワードに基づいて文書蓄積手段1内の文書が検索される。検出された文書4aはキーワード関連付け手段5に渡され、文書4aの内容中のキーワードと、キーワードの抽出元となる被関連付け対象文書2aの処理対象要素とが関連付けられる。そして、処理対象要素との関連付けが行われた文書5aは、文書蓄積手段1に戻される。30

#### 【0028】

このような処理を、文書蓄積手段1に格納されている全ての文書を被関連付け対象文書2aとして実行すれば、ある文書中のキーワードが他の文書中の特定の要素（表題や見出し）に関連付けられ、さらに、その要素から下位構造に関連付けられる。そのため、文書蓄積手段1内の文書を閲覧する場合には、文書中のキーワードから他の文書中の必要最小限の関連付けられた内容を参照することができる。40

#### 【0029】

しかも、関連付けに際して文書中の表題もしくは見出しなどの特定の要素だけを対象としてキーワード抽出処理を行うので、形態素解析のようなキーワード抽出に必要な煩雑な処理を文書全体に対して施す必要がなくなる。その結果、関連付けの処理効率が向上する。

#### 【0030】

次に、本発明の文書関連付け装置によって文書間の関連付けを行い、それらの文書を閲覧することができる文書閲覧装置を第1の実施の形態として以下に説明する。

#### 【0031】

図2は、本発明を適用した文書閲覧装置の構成を示す図である。この文書閲覧装置は、文書蓄積部11、階層構造関連付け部12、キーワード抽出部13、文書内容検索部14、キーワード関連付け部15、文書抽出部16、見出し抽出部17、見出し選択部18、内容抽出部19、表示部20、及び入力部21から構成されている。

【0032】

文書蓄積部11は、表題、章の見出し、節の見出し、段落等の論理構造を有する文書群を蓄積する。

階層構造関連付け部12は、文書蓄積部11に蓄積された文書を読み込み、表題、見出しの階層(章見出し、節見出しなど)、見出しに対応する内容(例えばある節の段落の並び)を関連付ける。

10

【0033】

キーワード抽出部13は、階層構造関連付け部12にて関連付けられた表題および見出しの階層からキーワードを抽出する。

文書内容検索部14は、キーワード抽出部13にて抽出されたキーワードを用いて、文書蓄積部11に蓄積された文書群を対象に、与えられたキーワードを内容に持つ文書を検索する。

【0034】

キーワード関連付け部15は、文書内容検索部14にて検索された文書中のキーワードと、該キーワードを抽出した表題および見出しの階層を関連付ける。

文書抽出部16は、文書蓄積部11に蓄積された文書群から、入力部21で利用者が入力した要求に応じて文書を抽出し、表示部20に表示する。

20

【0035】

見出し抽出部17は、文書抽出部16により抽出され、表示部20に表示された文書中で、利用者が入力部21によりキーワードを指定した場合に、指定されたキーワードで関連付けられている他の文書の表題もしくは見出しを文書蓄積部11から抽出し、表示部20に表示する。また、抽出された前記表題もしくは見出しのさらに下位の見出しを文書蓄積部11から抽出し、表示部20に表示する。

【0036】

見出し選択部18は、入力部21で利用者が入力した要求に応じて、見出し抽出部17により表題もしくは見出しが複数抽出された場合にはそのうちの1つの表題もしくは見出しへを選択し、前記表題もしくは見出しに下位の見出しが複数存在する場合にはそのうちの1つの見出しへを選択する。

30

【0037】

内容抽出部19は、見出し抽出部17により抽出された表題、見出しあわせて順次抽出された下位の見出しが、その見出しに対応する内容と関連付けられている場合に、文書蓄積部11からその内容を抽出し、表示部20に表示する。

【0038】

表示部20は、文書抽出部16により抽出された文書、見出し抽出部17により抽出された他の文書の表題もしくは見出し、および内容抽出部19により抽出された他の文書の内容を、画面上に表示する。

40

【0039】

入力部21は、文書抽出部16により抽出する文書の指定、文書抽出部16により抽出された文書中のキーワードの選択、見出し抽出部17により抽出された表題もしくは見出しが複数存在する場合の選択の指示等を行う。

【0040】

次に、このような構成の文書閲覧装置により、文書蓄積部11に格納されている文書群に対して文書間の関連付けを行う手順について説明する。

図3は、文書間の関連付けを行う手順を示すフローチャートである。以下の処理をステップ番号に沿って説明する。

[S1] 階層構造関連付け部12が、文書蓄積部11から未処理の文書を1つ読み込む。

50

[ S 2 ] 階層構造関連付け部 1 2 が、読み込んだ文書の構造を解析する。

[ S 3 ] 階層構造関連付け部 1 2 が、表題、見出し、及び内容を関連付ける。

[ S 4 ] キーワード抽出部 1 3 が、表題及び見出しの内容の中からキーワードを抽出する。

[ S 5 ] 文書内容検索部 1 4 が、キーワード抽出部 1 3 が抽出したキーワードを含む文書を、文書蓄積部 1 1 の中から検索する。

[ S 6 ] キーワード関連付け部 1 5 が、文書内容検索部 1 4 によって検出された文書内のキーワードに合致した部分に対して、そのキーワードの抽出元となった表題もしくは見出しを関連付ける。

[ S 7 ] キーワード関連付け部 1 5 が、キーワードの関連付けの終了した文書を文書蓄積部 1 1 へ格納する。 10

[ S 8 ] 階層構造関連付け部 1 2 は、文書蓄積部 1 1 に格納されている全ての文書の処理を行ったか否かを判断し、全ての文書に対する処理が終了していれば文書間の関連付け処理を終了し、そうでなければステップ S 1 に進み未処理の文書に対する処理を行う。

#### 【 0 0 4 1 】

このような処理を行うことにより、各文書の内容に含まれるキーワードから、そのキーワードを表題もしくは見出しとして含む文書の該当する表題もしくは見出しへリンクを張ることができる。

#### 【 0 0 4 2 】

以下に、具体例を用いて処理内容の詳細を説明する。なお、以下の例では、表題、見出し等の論理構造を有する文書の一例として、国際規格である S G M L (Standard Generalized Markup Language; ISO8879) に基づく表現を用いているが、表題、見出し、見出しに対応する内容が表現できる体系であれば S G M L でなくともよい。 20

#### 【 0 0 4 3 】

まず、階層構造関連付け部 1 2 が、文書蓄積部 1 1 に蓄積された文書を 1 つ読み込む（ステップ S 1）。ここで、以下のような文書を読み込んだものとする。図 4 は、関連付けの対象となるキーワードを見出しに含む文書の第 1 の例を示す図である。この文書 3 1 は、以下のような構造定義に従って作成されている。

#### 【 0 0 4 4 】

文書中の各要素は、その開始と終了を示すタグによって囲まれている。ある要素 A について、開始タグは < A > 、終了タグは < / A > で示される。文書は、文書の開始を示すタグ < doc > と、文書の終了を示すタグ < / doc > によって囲まれている。文書要素(doc) は表題を示す要素(title) と章を示す要素(sect1) の並びとを包含している。章要素(sect1) は見出しを示す要素(head) と段落を示す要素(para) の並びとを包含しているか、もしくは、見出し要素(head) と節を示す要素(sect2) の並びを包含している。節要素(sect2) は見出し要素(head) と段落要素(para) の並びを包含している。また、表題要素(title) 、見出し要素(head) 、段落要素(para) は、その内容としてテキスト(文字列)を持つ。 30

#### 【 0 0 4 5 】

なお、本実施の形態で例示する文書では、要素の名前として doc 、 title 、 sect1 、 sect2 、 head 、 para を用いているが、文書中で表題、見出し、本文が特定できれば、名前はなんでもよい。また、章や節の構造はさらに深く入れ子になっていてもよい。例えば、節要素(sect2) がさらに下位の節要素(sect3) を含むようになっていてもよい。 40

#### 【 0 0 4 6 】

このような文書 3 1 を読み込んだ階層構造関連付け部 1 2 は、読み込んだ文書の表題、見出し、段落等の文書構造を解析し、文書中の各要素に一意な識別子を付与する（ステップ S 2）。

#### 【 0 0 4 7 】

図 5 は、各要素に一意な識別子を付与した文書を示す図である。この図では、各要素に属性名「 id 」の値として識別子を付与している。この文書 3 2 では、文書要素(doc) に「 d1 」という識別子を付与している。文書要素の識別子が、文書 3 2 自身の識別子となる。そ 50

のため、文書要素の識別子は、文書蓄積部11に格納されている文書の中で一意に識別できるような記号が用いられる。

#### 【0048】

文書32中の文書要素以外の要素に関しては、文書32内において一意に識別できればよい。ここでは、表題要素(title)に「t1」という識別子を付与し、章要素(sect1)にそれぞれ「s1」、「s2」、「s3」という識別子を付与し、見出し要素(head)にそれぞれ「h1」、「h2」、「h3」という識別子を付与し、段落要素(para)にそれぞれ「p1」、「p2」、「p3」、「p4」という識別子を付与している。

#### 【0049】

次に、階層構造関連付け部12は文書32の表題、見出し、もしあれば下位の見出し、見出しに対応する段落の並びを関連付ける(ステップS3)。本実施の形態では、文書の表題から見出しへの関連付けを、表題要素(title)の属性として見出しの識別子の並びを設定することによって表現する。また、見出しから下位の見出しへの関連付けもしくは見出しから対応する内容への関連付けは、見出し要素(head)の属性として下位の見出し要素の識別子もしくは内容となる段落要素(para)の識別子の並びを設定することによって表現する。

10

#### 【0050】

図6は、表題、見出し、内容を関連付けた文書の例を示す図である。この文書33は、図5に示す文書32の表題要素および見出し要素に、関連付ける見出し要素もしくは段落要素の識別子の並びを属性名「ref」の値として付与したものである。この例では、識別子の並びを空白文字によって区切っている。例えば、表題要素(title)の下位には3つの見出し要素(head)があるため、表題要素(title)の属性名「ref」の値は、「h1 h2 h3」となる。

20

#### 【0051】

次に、キーワード抽出部13が階層構造関連付け部12によって関連付けられた表題もしくは見出しからキーワードを抽出する(ステップS4)。キーワードの抽出方法としては、従来の形態素解析などの手法を利用すればよい。本実施の形態では、形態素解析の結果から名詞と判定された単語をキーワードとして利用する。また、ひらがな語など、キーワードになりにくいものは、予めストップワードとして登録しておき、キーワードの抽出対象から外す。キーワード抽出部13は、要素と、その要素に含まれるキーワードとの対応関係を示すキーワード対応表を作成し、一時的に保持する。

30

#### 【0052】

図7は、キーワード対応表の例を示す図である。これは、図6に示した文書33の表題要素(title)および見出し要素(head)と、そこから抽出したキーワードとの対応関係を示すキーワード対応表41である。キーワード対応表41には、「要素の種類」、「識別子」、および「キーワード」の項目が設けられている。「要素の種類」の項目には、キーワードの抽出を行った要素の種類が設定される。この例は、「表題」か「見出し」のいずれかである。「識別子」の項目には、キーワードの抽出を行った要素の識別子が設定される。「キーワード」の項目には、キーワードの抽出を行った要素に含まれていたキーワードの集合が設定される。

40

#### 【0053】

このように、文書中の表題要素および見出し要素のみに対して形態素解析処理を行うので、文書全体に対して形態素解析処理を行う必要はない。一般に文書の表題や見出しに含まれるテキストの量は、文書全体のテキスト量に比して非常に少ないので、形態素解析の処理コストを大幅に削減することができる。

#### 【0054】

次に、文書内容検索部14は、キーワード抽出部13により抽出されたキーワードを用いて、文書蓄積部11に蓄積された他の文書の内容を検索する(ステップS5)。例えば、表題要素(title)から抽出された「SGML」というキーワードを用いて、文書蓄積部11内の文書を検索を行った場合、以下のような文書が検出される。

50

**【0055】**

図8は、関連付けの対象となるキーワードを本文中に含む文書の例を示す図である。この文書51は、段落要素(para)の内容に含まれるテキスト「...SGMLへ変換する。...」の「SGML」が一致したことにより、検出される。なお、この文書51は、図4に示した文書31と同様の構造定義に従って作成された文書である。

**【0056】**

図8のような文書51が見つかったら、そのキーワード関連付け部15はキーワードと一致する文書51の内容と、そのキーワードを含む表題もしくは見出しを関連付ける(ステップS6)。具体的には、テキスト「...SGMLへ変換する。...」中の「SGML」を参照元要素としてタグ付けし、図6に示した文書33の表題要素(title)の識別子を、参照元の要素の属性として設定する。

10

**【0057】**

図9は、キーワードと表題との関連付けが行われた文書の例を示す図である。この文書52では、キーワード「SGML」は関連付けを示す要素(link)の開始タグと終了タグによって囲まれ、link要素の属性「ref」の値として文書「d1」の表題「t1」への関連付けが設定されている。ここで属性「ref」の値として、文書要素の識別子「d1」と表題要素の識別子「t1」を「.」によって接続しているのは、識別子「t1」が他の文書のある要素においてたまたま使われている場合に、関連付けの対象を一意に決定できなくなることを防ぐためである。

**【0058】**

20

なお、本実施の形態では文書要素の識別子と表題要素もしくは見出し要素とを接続するために「.」を用いているので、要素に識別子を付与する際には識別子自身に「.」を含めないようにする。

**【0059】**

また、本実施の形態では、文書要素(doc)の識別子が、文書蓄積部11に蓄積されている文書を一意に識別できるように付与されているため、この文書要素を用いて文書を識別しているが、文書を識別するための識別子を文書全体に対して付与して、それを関連付けの識別子として用いてもよい。このような識別子としては、文書の実体がファイルである場合にはファイル名を用いたり、文書がWWW(World Wide Web)上で公開される場合にはURL(Uniform Resource Locator)を用いたりすることができる。

30

**【0060】**

ステップS4にて抽出された全てのキーワードに対して他の文書内容を検索し、ステップS6にてキーワードの関連付けが終了したら、関連付けされた文書は文書蓄積部11に格納される(ステップS7)。このとき、関連付けの対象となった元の文書の内容は上書きされる。

**【0061】**

そして、文書蓄積部11に蓄積された全ての文書について、上記ステップS1～ステップS7の処理が行われたかどうかを調べ(ステップS8)、まだ処理されていない文書があればステップS1へ戻って処理を継続し、全ての文書について処理が終了していれば、文書間の関連付けの処理を終了する。

40

**【0062】**

以上の処理が行われることにより、図9に示した文書52に対しても、階層構造の関連付けが行われる。

図10は、図9の文書に対して階層構造の関連付けを行った結果を示す図である。この文書53は、文書要素(doc)の識別子として「d2」が付与されている。

**【0063】**

次に、本発明に基づく文書関連付け装置により、関連付けを利用して、文書中のあるキーワードから、そのキーワードに対する説明記述を参照する手順について説明する。

**【0064】**

図11は、関連付けの利用手順を示すフローチャートである。このフローチャートをステ

50

ップ番号に沿って簡単に説明する。

[S11] 利用者が入力部21を用いて文書の表示要求を入力すると、文書抽出部16が該当する文書を文書蓄積部11内から抽出する。抽出した文書の内容は、表示部20の画面に表示される。

[S12] 利用者が入力部21を用いてキーワードを選択する。

[S13] 見出し抽出部17が、ステップS12にて選択されたキーワードの関連付け情報すなわちlink要素の属性「ref」の識別子を参照し、文書蓄積部11から該当する識別子を持つ文書の表題もしくは見出しを抽出する。あるいは後述するステップS14, S15で見出し選択部18によって選択された表題もしくは見出しの下位の見出しを、文書蓄積部11から抽出する。そして、抽出した表題もしくは見出しを表示部20に表示する。10

[S14] 見出し選択部18が、見出し抽出部17によって抽出された見出しが複数か否かを判断し、複数であればステップS15へ処理を進め、1つだけであればその表題もしくは見出しを選択してステップS16へ処理を進める。

[S15] 見出し選択部18が、入力部21で利用者が入力した要求に応じて、見出し抽出部17により表題もしくは見出しが複数抽出された場合にはそのうちの1つの表題もしくは見出しを選択する。

[S16] 見出し選択部18は、選択された表題もしくは見出しに関して、下位の見出しが存在するか否かを判断する。この実施の形態では、ステップS13にて抽出された表題要素(title)もしくは見出し要素(head)の属性「ref」の値として設定されている識別子を持つ要素を特定し、その要素が見出し要素(title)であるかないかを判定する。下位の見出しが存在していればステップS13に進み、存在していなければステップS17に進む。20

[S17] 内容抽出部19が、ステップS15にて選択された見出し要素に関連付けられた内容に対応する要素を抽出し、表示部20の画面に表示する。

#### 【0065】

以下に、関連付けの利用に関する処理を具体例を用いて説明する。

まず利用者が図10に示した文書53の表示要求を入力部21により指示したものとする。すると、文書53の内容が表示部20の画面に表示される。

#### 【0066】

図12は、文書の内容を表示した際の表示画面の例を示す図である。この表示画面61では、文書中のタグにより表題、見出し、段落、関連付けられたキーワードなどを識別し、それぞれに対して適切なレイアウトを定めて画面表示を行っている。例えば表題は大きめのフォントでセンタリングして表示し、見出しあは大きめのフォントで番号を付与して表示し、他の文書の見出し等に関連付けられたキーワードは下線を付与して強調している。30

#### 【0067】

次に、利用者が、表示部20に表示された文書を参照し、関連付けの付与された「SGML」の表示箇所をマウスでクリックするなどの方法で選択したものとする(ステップS12)。すると、見出し抽出部17が、選択されたキーワード「SGML」の関連付け情報すなわちlink要素の属性「ref」の識別子を参照し、文書蓄積部11から該当する識別子「d1」を持つ文書33内の該当する表題「t1」を抽出し、表示部20に表示する(ステップS13)。40

#### 【0068】

図13は、見出しを表示した際の表示画面の例を示す図である。前述の関連付けの処理によりキーワード「SGML」は関連付けを示すlink要素によってタグ付けされており、その属性「ref」の値として「d1.t1」が設定されているので、図6に示した文書33の表題要素(識別子は「t1」)が見出し抽出部17により抽出され、表題要素の内容「SGMLによる電子出版」を含む表示画面62が、表示部20により表示される。

#### 【0069】

このとき、抽出された表題が複数か否かの判定が見出し抽出部17によって行われるが(ステップS14)、この例では抽出された表題もしくは見出しが1つだけである。そこで50

、見出し抽出部 17 は、抽出された見出しに関連付けられた下位の見出しが存在するかどうかを判定する（ステップ S16）。この例では、識別子「t1」を持つ表題要素の属性「ref」の値として、「h1 h2 h3」の3つの要素が関連付けられており、いずれも見出し要素である。従って、ステップ S13 へ戻り見出しの抽出が行われる。

#### 【0070】

図14は、下位の見出しを表示した際の表示画面の例を示す図である。これは、図13に示した表示画面62の例から、「SGMLによる電子出版」を内容に持つ表題要素に関連付けられている下位の見出しを表示部20に表示したときの表示画面63の例を示したものである。すなわち、図6に示した文書33において、識別子「t1」を持つ表題要素の属性「ref」の値として設定されている3つの見出し要素（識別子はh1、h2、h3）の内容「はじめに」「電子出版の歴史」「関連ツール」を抽出し、表示部20の画面に表示している。10

#### 【0071】

ここで、再び見出し選択部18が、抽出された見出しが複数であるか否かの判断を行う（ステップS14）。ここでは、3つの見出しが抽出されているので、利用者は表示部20に表示されている複数の表題もしくは見出しから入力部21により1つを選択する（ステップS15）。この例では、図14に表示されている3つの見出しの内容のうち「関連ツール」をマウス等で選択したものとする。

#### 【0072】

すると、見出し選択部18が、選択された見出し「関連ツール」に関連付けられた下位の見出しが存在するかどうかを判定する（ステップS16）。図6に示した文書33において、「関連ツール」を内容に持つ見出し要素（識別子は「h3」）の属性「ref」の値として設定されている識別子p3、p4、...の要素はいずれも見出しへではない。したがって、内容抽出部19が、内容の抽出を行う（ステップS17）。

#### 【0073】

図15は、内容を表示した際の表示画面の例を示す図である。これは、図14に示した表示画面63の例から、「関連ツール」を内容に持つ見出し要素に関連付けられている内容を表示部20に表示したときの表示画面64の例である。すなわち、図6に示した文書33において、識別子「h3」を持つ見出し要素の属性「ref」の値として設定されている段落要素（識別子p3、p4、...）の内容を抽出し、表示部20に表示する。

#### 【0074】

このように、関連する内容の候補が複数存在する場合にも、見出しを表示して選択することにより必要最小限の関連付けられた内容を参照することができる。また、表示部20に表示される表題もしくは見出しから、利用者が内容を参照する必要がないと判断した場合は、内容の参照を行う前に処理を中断することも可能である。したがって、利用者は内容の詳細を全て読むことなく必要な情報を効率良く見つけることが可能である。30

#### 【0075】

次に、第2の実施の形態について説明する。第2の実施の形態は、ある文書内容中のキーワードに対して、他の文書の表題もしくは見出しが複数関連付けられている場合に、関連付けられた内容をさらに効率的に抽出できるようにした文書閲覧装置である。なお、第2の実施の形態の構成要素は、図2に示した第1の実施の形態の構成要素と同じであるため、図2に示した構成を用いて第2の実施の形態を説明する。また、第2の実施の形態における文書間の関連付け処理は、第1の実施の形態と同様であるため説明を省略する。40

#### 【0076】

そこで、第2の実施の形態による関連付け参照処理について、以下に説明する。

図16は、第2の実施の形態における関連付け参照の処理の流れを示すフローチャートである。以下の処理をステップ番号に沿って説明する。

[S21] 利用者が文書蓄積部11に蓄積された文書群から抽出する文書を入力部21により指示すると、文書抽出部16は、指示された文書を抽出し、表示部20に表示する。

[S22] 利用者が表示部20に表示された文書を参照し、入力部21より関連付けの付与されたキーワードの表示箇所をマウスでクリックするなどの方法で選択する。50

[S23] 見出し抽出部17は、ステップS22にて選択されたキーワードの関連付け情報すなわちlink要素の属性「ref」の識別子を参照し、文書蓄積部11から該当する識別子を持つ文書の表題もしくは見出しを抽出する。

[S24] 見出し抽出部17は、ステップS23にて抽出された表題もしくは見出しが1つであるか複数であるかを判定し、抽出された表題もしくは見出しが複数あれば、ステップS25へ進み、1つしかなければステップS29へ進む。

[S25] 見出し抽出部17は、ステップS24にて抽出された表題もしくは見出しが複数あると判定されると、それらの表題もしくは見出しを文書ごとにグループ化する。

[S26] 見出し抽出部17は、ステップS25にてまとめられた文書ごとの関連付けのグループを、同一文書内への関連付けの数、および関連付けられる表題もしくは見出しの階層の深さから算出される重要度に応じて並べ替える。  
10

[S27] 見出し抽出部17は、ステップS25にて文書ごとにグループ化された関連付けを、関連付けられる表題もしくは見出しの階層の深さから算出される重要度に応じて各グループ内で並び替える。

[S28] 利用者は表示部20に表示されている複数の表題もしくは見出しから入力部21により1つを選択する。

[S29] 見出し抽出部17は、ステップS23にて抽出された表題もしくは見出しが1つである場合またはステップS28にて見出しが選択された場合に、その表題もしくは見出しに関連付けられた下位の見出しが存在するかどうかを判定する。もし下位の見出しが存在すればステップS23に戻って下位の見出しを抽出する。下位の見出しが存在しなければステップS30へ進む。  
20

[S30] 内容抽出部19が、ステップS28にて選択された見出し要素に関連付けられた内容に対応する要素を抽出し、表示部20の画面に表示する。

#### 【0077】

このようにして、ある文書内容中のキーワードに対して、他の文書の表題もしくは見出しが複数関連付けられている場合に、関連付けられた内容を効率的に抽出することができる。以下にこの処理の詳細を、具体例を用いて説明する。

#### 【0078】

本実施の形態では、第1の実施の形態で示した文書以外に、関連付けの対象となるキーワード「SGML」を表題に含む次のような文書が、文書蓄積部11に格納されているものとする。  
30

#### 【0079】

図17は、関連付けの対象となるキーワードを表題に含む文書の第2の例を示す図である。この文書71には、文書要素(doc)に「d3」という識別子が付与されている。また、「id="t1"」の表題要素(title)、「id="h2"」の見出し要素(head)、および「id="h3"」の見出し要素(head)の内容に「SGML」のキーワードが含まれている。

#### 【0080】

図18は、関連付けの対象となるキーワードを表題に含む文書の第3の例を示す図である。この文書81には、文書要素(doc)に「d4」という識別子が付与されている。また、「id="h21"」の見出し要素(head)と「id="h22"」の見出し要素(head)との内容に「SGML」のキーワードが含まれている。  
40

#### 【0081】

図4に示した文書31に加え、図17、図18に示した文書71、81に対して関連付け処理が行われると、図8に示した文書51は以下のように、他の文書の表題もしくは見出しに関連付けられる。

#### 【0082】

図19は、キーワードと表題もしくは見出しとの関連付けを行った文書の例を示す図である。この図に示すように、文書54は、他の複数の文書の表題もしくは見出しに関連付けられている。すなわち、図19において、キーワード「SGML」に対してそれをタグ付けするlink要素の属性によって、文書「d1」の表題「t1」( 内容は「SGMLによる電子出版」 )  
50

、文書「d3」の表題「t1」( 内容は「SGMLへの招待」) 、見出し「h2」( 内容は「SGMLとHTML」) および見出し「h3」( 内容は「SGMLとXML」) 、文書「d4」の見出し「h21」( 内容は「SGML文書の検索」) および見出し「h22」( 内容は「SGMLデータベースシステム」) の合計 6 個の表題もしくは見出しが関連付けられている。

#### 【0083】

以下、このように関連付けられている文書群を対象として、図 16 に示したフロー チャートに沿って関連付け参照の流れを説明する。

まず利用者が文書蓄積部 11 に蓄積された文書群から抽出する文書を入力部 21 により指示すると、文書抽出部 16 は、指示された文書を抽出し、表示部 20 に表示する(ステップ S21)。ここで表示部 20 に表示される文書は図 19 に示した文書 54 であるものとする。図 19 に示す文書 54 を表示部 20 に表示した場合、link要素の属性値は画面上に表示されないので、第 1 の実施の形態の場合と同じく図 12 に示すように表示画面 61 が表示される。

#### 【0084】

次に、利用者が表示部 20 に表示された文書 54 を参照し、入力部 21 より関連付けの付与されたキーワード「SGML」の表示箇所をマウスでクリックするなどの方法で選択する(ステップ S22)。見出し抽出部 17 は、ステップ S22 にて選択されたキーワードの関連付け情報すなわち link要素の属性「ref」の識別子を参照し、文書蓄積部 11 から該当する識別子を持つ文書の表題もしくは見出しが抽出する(ステップ S23)。

#### 【0085】

次に、見出し抽出部 17 は、ステップ S23 にて抽出された表題もしくは見出しが 1 つであるか複数であるかを判定する(ステップ S24)。図 19 に示した例では、合計 6 個の表題もしくは見出しが抽出されるので、ステップ S25 へ進む。

#### 【0086】

次に、見出し抽出部 17 は、ステップ S24 にて抽出された表題もしくは見出しが複数あると判定されると、それらの表題もしくは見出しが文書ごとにグループ化する(ステップ S25)。図 19 の文書 54 では、文書「d1」の表題「t1」を 1 つのグループに、文書「d2」の表題「t1」、見出し「h2」および見出し「h3」を 1 つのグループに、文書「d3」の見出し「h21」および見出し「h22」を 1 つのグループにまとめる。

#### 【0087】

このように、抽出された表題もしくは見出しが文書ごとにグループ化することで、同一文書内の関連する記述を連続して参照することができるようになる。

次に、見出し抽出部 17 は、ステップ S25 にてまとめられた文書ごとの関連付けのグループを、同一文書内への関連付けの数、および関連付けられる表題もしくは見出しが階層の深さから算出される重要度に応じて並べ替える(ステップ S26)。本実施の形態では文書ごとの重要度を次の式によって算出する。

#### 【0088】

#### 【数 1】

$$\text{重要度} = \sum_{i=1}^n 2^{-d_i}$$

. . . . . (1)

#### 【0089】

式(1)において、n は、その文書で関連付けられている表題もしくは見出しが対して 1 から順に割り振られた数字の最大値を表す。di は、数字(i)が割り振られた表題もしくは見出しが階層構造における深さを表す(表題の深さを 0 とする)。すなわち、表題に

10

20

30

40

50

については  $d_i = 0$ 、第1レベルの見出しについては  $d_i = 1$ 、第2レベルの見出しについては  $d_i = 2$  などとなる。式(1)に従って各文書の重要度を計算すると、図6に示した文書33は表題「t1」が1つだけ関連付けられているので重要度 =  $2^{-0} = 1$ 、図17に示した文書71は表題「t1」、見出し「h2」および見出し「h3」の3つが関連付けられているので重要度 =  $2^{-0} + 2^{-1} + 2^{-1} = 2$ 、図18に示した文書81は見出し「h21」および見出し「h22」の2つが関連付けられているので重要度 =  $2^{-2} + 2^{-2} = 0.5$  となる。したがって、文書ごとの重要度にしたがって文書「d2」、文書「d1」、文書「d3」の順に関連付けのグループを並べ替える。

#### 【0090】

なお、文書ごとの重要度の算出方法は、式(1)に示したものに限定されるわけではない。関連付けられる表題もしくは見出しが多いほうが重要度がより高くなるように、また、関連付けられる表題もしくは見出しの階層の深さが浅いほうが重要度がより高くなるように重要度を決めればよい。このような重要度の決定方法は、同一文書内で関連付けられる表題もしくは見出しが多いほうが、そのキーワードが文書全体の主題に関係する可能性が高いと考えられ、また、関連付けられる表題もしくは見出しの階層の深さが浅いほうが、そのキーワードについてより包括的に説明されている可能性が高いと考えられるので、有効な方法である。

#### 【0091】

次に、見出し抽出部17は、ステップS25にて文書ごとにグループ化された関連付けを、関連付けられる表題もしくは見出しの階層の深さから算出される重要度に応じて各グループ内で並び替える(ステップS27)。本実施の形態では、階層の深さが浅いほうが重要度が高いものとする。また、階層の深さが同一である場合には、文書中で先に出現するほうが重要度が高いものとする。あるいは、文書中の出現順序を優先した重要度を用いてもよい。

#### 【0092】

以上の処理が行われた後、抽出された表題もしくは見出しが表示部20に表示される。図20は、複数の見出しを表示する表示画面の例を示す図である。これは、図12に示した表示画面61中でキーワード「SGML」を選択したときに表示される表示画面101の例を示したものである。図20に表示されている表題もしくは見出しあは、上記処理により、文書ごとにグループ化され、重要度順に並べ替えられている。

#### 【0093】

次に、利用者は表示部20に表示されている複数の表題もしくは見出しから入力部21により1つを選択する(ステップS28)。すると、見出し抽出部17は、ステップS23にて抽出された表題もしくは見出しが1つである場合またはステップS28にて見出しが選択された場合に、その表題もしくは見出しに関連付けられた下位の見出しが存在するかどうかを判定する(ステップS29)。

#### 【0094】

このように、関連付けられる表題もしくは見出しが同一文書内に複数存在する場合や、関連付けられる表題もしくは見出しを持つ文書が複数存在する場合に、重要なものから優先的に参照できるので、たとえ1つのキーワードに多量の文書の表題や見出しが関連付けられている場合でも、効率的に関連付けられた内容を参照することができる。

#### 【0095】

なお、上記の処理機能は、コンピュータによって実現することができる。その場合、文書関連付け装置及び文書閲覧装置が有すべき機能の処理内容は、コンピュータで読み取り可能な記録媒体に記録されたプログラムに記述しておく。そして、このプログラムをコンピュータで実行することにより、上記処理がコンピュータで実現される。コンピュータで読み取り可能な記録媒体としては、磁気記録装置や半導体メモリ等がある。市場に流通させる場合には、CD-ROM(Compact Disk Read Only Memory)やフロッピーディスク等の可搬型記録媒体にプログラムを格納して流通させたり、ネットワークを介して接続されたコンピュータの記憶装置に格納しておき、ネットワークを通じて他のコンピュータに転送

10

20

30

40

50

することもできる。コンピュータで実行する際には、コンピュータ内のハードディスク装置等にプログラムを格納しておき、メインメモリにロードして実行する。

#### 【0096】

##### 【発明の効果】

以上説明したように、本発明の文書関連付け装置では、文書中のキーワードと被関連付け対象文書の処理対象要素とを関連付けるとともに、被関連付け対象文書中の要素の上位構造と下位構造とを関連付けるようにしたため、文書中のキーワードから他の文書中の要素及びその要素の下位構造を順次辿ることができ、必要最小限の関連付けられた内容を参照することができる。しかも、特定の要素からのみキーワードの抽出を行うため、キーワード抽出に伴う複雑な処理を限られた範囲に対して実行することができ、関連付け処理を高速に行うことが可能となる。10

#### 【0097】

また、本発明の文書閲覧装置では、文書中のキーワードと被関連付け対象文書の処理対象要素とを関連付けるとともに、被関連付け対象文書中の要素の上位構造と下位構造とを関連付けておき、文書中のキーワードが指定されると、そのキーワードの関連要素の内容とその下位構造の内容を抽出するようにしたため、キーワードを指定したユーザは、そのキーワードに関する必要最小限の関連要素の内容を参照することができる。

#### 【0098】

また、本発明の文書関連付けプログラムを記録したコンピュータ読み取り可能な記録媒体では、記録された文書関連付けプログラムをコンピュータに実行させることにより、文書中のキーワードと被関連付け対象文書の処理対象要素とを関連付けるとともに、被関連付け対象文書中の要素の上位構造と下位構造とを関連付ける処理を、コンピュータに高速に行わせることができる。すなわち、文書中のキーワードを他の文書の最小限の関連記述に関連付ける処理を、コンピュータに高速に行わせることができる。20

#### 【0099】

また、本発明の文書閲覧プログラムを記録したコンピュータ読み取り可能な記録媒体では、記録された文書閲覧プログラムをコンピュータに実行させることにより、文書中のキーワードと被関連付け対象文書の処理対象要素とを関連付けるとともに、被関連付け対象文書中の要素の上位構造と下位構造とを関連付けておき、文書中のキーワードが指定されると、そのキーワードの関連要素の内容とその下位構造の内容を抽出するような処理をコンピュータに行わせることができる。すなわち、コンピュータに対してキーワードを指定したユーザは、そのキーワードに関する必要最小限の関連要素の内容を参照することができる。30

##### 【図面の簡単な説明】

【図1】 本発明の原理構成図である。

【図2】 本発明を適用した文書閲覧装置の構成を示す図である。

【図3】 文書間の関連付けを行う手順を示すフローチャートである。

【図4】 関連付けの対象となるキーワードを見出しに含む文書の第1の例を示す図である。

【図5】 各要素に一意な識別子を付与した文書を示す図である。

【図6】 表題、見出し、内容を関連付けた文書の例を示す図である。

【図7】 キーワード対応表の例を示す図である。

【図8】 関連付けの対象となるキーワードを本文中に含む文書の例を示す図である。

【図9】 キーワードと表題との関連付けが行われた文書の例を示す図である。

【図10】 図9の文書に対して階層構造の関連付けを行った結果を示す図である。

【図11】 関連付けの利用手順を示すフローチャートである。

【図12】 文書の内容を表示した際の表示画面の例を示す図である。

【図13】 見出しを表示した際の表示画面の例を示す図である。

【図14】 下位の見出しを表示した際の表示画面の例を示す図である。

【図15】 内容を表示した際の表示画面の例を示す図である。

40

50

【図16】 第2の実施の形態における関連付け参照の処理の流れを示すフロー チャートである。

【図17】 関連付けの対象となるキーワードを表題に含む文書の第2の例を示す図である。

【図18】 関連付けの対象となるキーワードを表題に含む文書の第3の例を示す図である。

【図19】 キーワードと表題もしくは見出しとの関連付けを行った文書の例を示す図である。


【図20】 複数の見出しを表示する表示画面の例を示す図である。

【符号の説明】


10

- 1 文書蓄積手段
- 2 階層構造関連付け手段
- 2 a 被関連付け対象文書
- 3 キーワード抽出手段
- 3 a キーワード対応表
- 4 文書内容検索手段
- 4 a 文書
- 5 キーワード関連付け手段
- 5 a 文書


【図1】



【図2】



【図3】



【図4】

31

```

<doc>
  <title>SGMLによる電子出版</title>
  <sect1 id="s1">
    <head>はじめに</head>
    <para>
      ...
    </para>
  </sect1>
  <sect1 id="s2">
    <head>電子出版の歴史</head>
    <para>
      ...
    </para>
  </sect1>
  <sect1 id="s3">
    <head>関連ツール</head>
    <para>ここでは、SGMLによる電子出版を実現する際に利用できるツールについて説明する。</para>
    <para>...
    </para>
  </sect1>
</doc>
  
```

【図5】

32

```

<doc id="d1">
  <title id="t1">SGMLによる電子出版</title>
  <sect1 id="s1">
    <head id="h1">はじめに</head>
    <para id="p1">
      ...
    </para>
    <sect1 id="s2">
      <head id="h2">電子出版の歴史</head>
      <para id="p2">
        ...
      </para>
    </sect1>
    <sect1 id="s3">
      <head id="h3">関連ツール</head>
      <para id="p3">ここでは、SGMLによる電子出版を実現する際に利用できるツールについて説明する。</para>
      <para id="p4">...
      </para>
    </sect1>
  </sect1>
</doc>
  
```

【図6】

33

```

<doc id="d1">
  <title id="t1" ref="h1 h2 h3 ...">SGMLによる電子出版</title>
  <sect1 id="s1">
    <head id="h1" ref="p1 ...">はじめに</head>
    <para id="p1">
      ...
    </para>
  </sect1>
  <sect1 id="s2">
    <head id="h2" ref="p2 ...">電子出版の歴史</head>
    <para id="p2">
      ...
    </para>
  </sect1>
  <sect1 id="s3">
    <head id="h3" ref="p3 p4 ...">関連ツール</head>
    <para id="p3">ここでは、SGMLによる電子出版を実現する際に利用できるツールについて説明する。</para>
    <para id="p4">...
    </para>
  </sect1>
</doc>
  
```

【図7】

41

要素の種類	識別子	キーワード
表題	t1	SGML、電子、出版
見出し	h1	-
見出し	h2	電子、出版、歴史
見出し	h3	関連、ツール

【図8】

51

```
<doc>
  <title>A大学における電子図書館システムの概要</title>
  <sect1>
    <head>はじめに</head>
    <sect2>
      <head>背景</head>
      <para>
        ...
      </para>
    </sect2>
    <sect2>
      <head>目的</head>
      <para>
        ...
      </para>
    </sect2>
  </sect1>
  <sect1>
    <head>システムアーキテクチャ</head>
    <para>
      ...
    </para>
    <para>
      ... SGMLへ変換する。...
    </para>
  </sect1>
</doc>
```

【図9】

52


```
<doc>
  <title>A大学における電子図書館システムの概要</title>
  <sect1>
    <head>はじめに</head>
    <sect2>
      <head>背景</head>
      <para>
        ...
      </para>
    </sect2>
    <sect2>
      <head>目的</head>
      <para>
        ...
      </para>
    </sect2>
  </sect1>
  <sect1>
    <head>システムアーキテクチャ</head>
    <para>
      ...
    </para>
    <para>
      ... <a href="d1.t1">SGML</a>へ変換する。...
    </para>
  </sect1>
</doc>
```

【図10】


53

```
<doc id="d2">
  <title id="t1" ref="h1 h2 ... "A大学における電子図書館システムの概要</title>
  <sect1 id="s1">
    <head id="h1" ref="h1 h2 ... "A大学における電子図書館システムの概要</head>
    <sect2 id="s11">
      <head id="h11" ref="h11 h12" >はじめに</head>
      <para id="p1" ref="p1" >背景</para>
      <para id="p2" >...
      </para>
    </sect2>
    <sect2 id="s12" >
      <head id="h12" ref="p2" >目的</head>
      <para id="p2" >...
      </para>
    </sect2>
  </sect1>
  <sect1 id="s2">
    <head id="h2" ref="p3 p4" >システムアーキテクチャ</head>
    <para id="p3" >...
    </para>
    <para id="p4" >...
    </para>
    <para id="p4" >...
    </para>
    <para id="p4" >...
    </para>
  </sect1>
</doc>
```


【図11】




【図12】




【図13】




【図14】



【 図 1 5 】



【 図 1 6 】



【 図 17 】

```
<doc id="d3">
  <title id="t1" ref="h1 h2 ... ">SGMLへの招待</title>
  <sect1 id="S1">
    <head id="h1" ref="p1 ... ">はじめに</head>
    <para id="p1">
      <br>
    </para>
  </sect1>
  <sect1 id="S2">
    <head id="h2" ref="p2 ... ">SGMLとHTML</head>
    <para id="p2">HTMLのアブリューイヨンの一つであり、...</para>
    <sect1 id="S3">
      <head id="h3" ref="p3 p4 ... ">SGMLとXML</head>
      <para id="p3">XML(electronic Markup Language)は、...</para>
      <para id="p4">...</para>
    </sect1>
  </sect1>
</doc>
```

【 図 1 8 】

```

<doc id="d4">
  <title id="t1" ref="h1 h2 h3 ... ">情報検索技術の最新動向</title>
  <head id="h1" ref="p1 ... ">はじめに</head>
  <para id="p1">
    <para>
      <sect1 id="s2">
        <head id="h2" ref="h2">構造化文書の検索</head>
        <sect2 id="s22" ref="p3 ... ">SGML文書の検索</head>
        <para id="p3" ...></para>
      </sect2>
      <sect2 id="s22" ref="p9 ... ">SGMLデータベースシステム</head>
    </head id="h2" ref="p9" ...></para>
  </para>
  <sect1 id="s2" ref="p9 ... ">SGMLデータベースシステム</head>
</doc>

```

【図19】

54

```

<doc id="d2">
  <title id="t1" ref="h1 h2 ...">A大学における電子図書館システムの概要</title>
  <sect1 id="S1">
    <head id="h1" ref="h11 h12">はじめに</head>
    <sect2 id="S1_1">
      <head id="h1_1" ref="p1">背景</head>
      <para id="p1">
        ...
      </para>
    </sect2>
    <sect2 id="S1_2">
      <head id="h1_2" ref="p2">目的</head>
      <para id="p2">
        ...
      </para>
    </sect2>
    <sect1 id="S2">
      <head id="h2" ref="p3 p4">システムアーキテクチャ</head>
      <para id="p3">
        ...
      </para>
      <para id="p4">
        ...
      </para>
      <link ref="d1 t1 d3 h2 d3 h3 d4 h21 d4 h22">SGML</link>へ変換する。...
    </sect1>
  </sect1>
</doc>

```

【図20】

101

A大学における電子図書館システムの概要	
1. はじめに 1.1 背景 1.2 目的	
2. システムアーキテクチャ SGML へ変換する。...	
SGMLへの招待 SGMLとHTML SGMLとXML -----           SGMLによる電子出版 -----           SGML文書の検索 SGMLデータベースシステム	