

A Hierarchical Clustering Method Aimed at Document Layout Understanding and Analysis

Costin-Anton Boiangiu, Dan-Cristian Cananau, Bogdan Raducanu and Ion Bucur

Abstract—This paper presents a new approach towards creating a type of hierarchy for document image page using the information given by the Delaunay triangulation. The steps of the algorithm are presented under the form of a cluster tree containing the information of the page in structures such as collections of pixels and using the distance between them as a binding measurement. The final result provides the page segmentation into clusters containing pictures, titles and paragraphs.

Keywords— cluster tree, contour detection, Delaunay triangulation, page hierarchy, pixel entities.

I. INTRODUCTION

The development in the area of scanning and printing devices has known a great expansion in the last years. And because of this reason there have been further increases in the expectations of the document content recognition and conversion. The purpose is the expansion of the electronic interpretation of the document by understanding the logical structure (chapter delimitation and titles, sections, headings, paragraphs, authors and affiliation, annotation, footnotes, references, commentaries, related pictures and schemes, page number) [13]-[15].

The goal of this paper is to present a solution towards determining this layout and to create a form of hierarchy for the document using this layout and the first step is to find the basic entities in a document and with them to create such a structure. These basic entities are represented by the separators, which can be roughly classified based on their shape or geometrical characteristics into:

- Line separators;
- Line-based separators;
- White space separators;
- Arbitrary-form separators;

The common knowledge on separators presents them as image segments that have certain geometrical characteristics, like, for example, in a horizontal line the width is much greater than the height. Most algorithms use only this

information towards detecting such entities and more evolved approaches respect the angle orientation of the separators for broken line detection. Such approaches are shape dependent and take into consideration just line separators. Better ones use the concept of distance and provide a mathematical solution for the detection like in the examples found in [11], [12], [23].

For the white-space detection, most algorithms are somehow similar to the ones used for lines because the detection is based on the fact that the number of white pixels found on a direction is greater than the number of the pixels found on a direction orthogonal to the initial one. Even though this approach has the same disadvantages as the one used for lines because of the size and orientation dependency, it proves to have a greater degree of certainty. However none of this type of approaches is satisfactory and a geometrical independent method is required for correct detection of separators (for further line detection algorithms refer to [2]).

In this paper a reliable approach will be presented, approach based on creating a hierarchical clustering structure [3].

What differentiates this method from others presented in similar papers is its type. It uses a “top-down” one instead of a “bottom-up”, which means that it does not have the purpose of grouping different objects into collections, but instead it breaks the collections into objects. The Delaunay triangulation ([8]-[10], [24]) presents the perfect mathematical tool towards obtaining neighborhood relations and further using them to simulate the characteristic of the human eye of “connecting” similar elements.

The final structure will be presented as a cluster tree. This will combine the results obtained from the triangulation a specific cluster tree construction algorithm. By using such a structure entities will be gathered into single components based on the distances computed by the triangulation. The tree will use the Euclidian distance as its measurement and will introduce a new definition, the “hierarchy distance”, in order to facilitate the merging operations done on the entities. All of these aspects shall be presented in the following pages.

II. PROBLEM SOLUTION

There are several steps that have to be followed in the correct order to obtain the final tree hierarchy. The first steps have been presented in a previous article ([4]) and are presented succinctly because they are mandatory for the correct completion of the final step.

Paper submitted on December 10, 2008 for review.

Costin-Anton Boiangiu, Ion Bucur, Bogdan Raducanu are with the Faculty of Automatic Control and Computers, “Politehnica” University of Bucharest, Bucharest, Splaiul Independentei 313, Romania, Postal Code 060042 (e-mail: costin.boiangiu@cs.pub.ro, ion.bebe.bucur@gmail.com, braducanu@gmail.com).

Dan-Cristian Cananau is with the Faculty of Engineering Taught in Modern Languages, “Politehnica” University of Bucharest, Bucharest, Splaiul Independentei 313, Postal Code 060042, Romania (e-mail: dan_cananau@yahoo.com).

A. Preprocessing

The initial step is a preprocessing one, because the input has to be prepared for the requirements of the algorithm [19]. One of the most important aspects of this approach is that it uses a black and white document and in order to achieve this goal for every document a simple black and white conversion has to be made regardless of the initial color pattern. There are several algorithms that serve this purpose we have selected the most suitable one for our kind of input documents [1],[21].

B. Contour generation

Next, the input selection has to be done and this implies generating the image segments (further referred as entities of the image). A collection of connected black pixels represents an entity, which is easily determined with the help of a simple algorithm that starts from a black pixel and passes through all neighboring black pixels until there are only white neighbors [18].




Fig. 1: a black and white conversion of an initial grayscale image.

By repeating this algorithm for all non-visited black pixels the entities are obtained in the end. There are several shapes that can bind a collection of black pixels. The actual bounding shape is in fact a polygon which contains and approximates the entity or collections of entities and in Fig. 2 we present the most common one: the rectangle.

For the presented approach the bounding rectangle is not used, but instead a contour of the current entity is taken into consideration. Because each entity can be seen as a collection of horizontal segments, the contour is generated from the extremities of each such segment of the entity, with the mention that all the extremity points of the segments which cannot be seen directly from an external point of view are not taken into consideration.

A simple example of this algorithm is presented below in Fig. 3. Another type of contour generation algorithm is presented in [5], [17].

Die Bundesregierung sagt voraus, daß es 1998 ein Wirtschaftswachstum von bis zu drei Prozent und am Jahresende weniger Arbeitslose geben wird. So steht es im Jahreswirtschaftsbericht, den das Kabinett am Mittwoch verabschiedete. Die Opposition sprach von „Schönfärberei“, Gewerkschaften vom „Prinzip Hoffnung“.

Fig.2.




Fig. 3: result of the contour detection algorithm

C. Delaunay triangulation

After the actual contour selection the next step is the use of the constrained Delaunay triangulation algorithm. In this way all the entities will be connected to each other.

However, this is more than we need and so a processing of the obtained Delaunay triangles has to be done. All the triangles that connect more or less than two entities are eliminated and the final result reveals only entities connected in groups of two.

This fact allows the creation of two types of points, which are named as a convention in this paper: current and destination points. The names come from their characteristic of belonging or not to an entity.

By using the Delaunay triangulation each entity has several triangles starting from it and going towards another entity. The points of the triangles which are on the current entity are the current points and the ones that belong to the triangles, but are situated on another entity different from the current one are called destination points.

D. Proximity generation

The proximity is an “entity to entity” relation. The proximities are generated by iterating toward the triangles contained in the constrained Delaunay triangulation and

filtering triangles that join two different (inter-triangles) entities. Triangles that are generated inside one entity (intra-triangles) or between three distinct entities are discarded from processing.

The proximity structure holds vital statistics regarding the entity-to-entity relation like: the pair of entities, the minimum square distance inside Delaunay inter-triangles, the number of connections points in both entities, the area of connection and other measures that may be relevant depending on the processing type.

E. Separators

There are several classifications of separators based on their geometrical form or characteristics as stated in the introduction, but all of them have one important thing in common which puts them into the spotlight. By using the already presented Delaunay triangulation and detecting the current and destination points a statistics can be made based on their ratio.

The result reveals a very important characteristic of separators: they have far more current points than destination points because they extend to several entities in size independent of the orientation or angle. In this way the separators are detected and a line can be drawn between them and regular characters, like letters or punctuation signs.

The next step is to use this information and introduce it in a hierarchy of the page. By doing so, we will get the text areas which will be bounded by page edges or separators inside the hierarchy tree.

III. CLUSTER TREE

Our method creates a hierarchical model of the input entities by building a special type of multi-way tree called a cluster tree. The entities will become leaves in such a tree and the internal nodes of the tree represent clusters of entities. The diameter of a cluster is the maximum distance between any two entities belonging to that cluster or between any adjacent entities that may form a chain to “connect” any entity pair (Fig. 4). The purpose of this tree is to group the entities into clusters with diameters in increasing order of magnitude. Thus, the root of the tree corresponds to a cluster with the largest possible diameter (if this cluster would represent the entire page, then its children would represent top level elements like paragraphs or images).

This hierarchical model is used in collaboration with the separator information obtained at the previous step to build the layout of the page [6]-[9].

There are two courses of action that can be considered when discussing the design of the hierarchy tree. The first one is to use as input the extreme points and the Delaunay triangulation. The extreme points are the points on the contour of the entities.

The tree construction algorithm starts by computing for each pair of entities the minimum length Delaunay triangle edge that connects them. The algorithm constructs the tree in a bottom-up fashion. It starts with a random entity and builds a cluster around it. It will first find the closest entity to this

initial entity and add it to the cluster. Next, it finds the closest entity to either of the two and if the distance to this entity is of the same order of magnitude as the distance between the first two, the third entity will also be added to the cluster. Similarly, the algorithm will continue to add entities until the closest entity is of a bigger order of magnitude and thus, cannot be part of this first cluster. The rest of the clusters are constructed in the same way, with the exception that the algorithm now may also add the closest cluster and not just the closest entity.

When the algorithm ends, it produces the desired tree model which accurately describes the hierarchy of the page.

The second approach to constructing the hierarchy is to use points from the bounding shapes of the entities and the distance between the bounding shapes as a metric.

A good choice for the bounding shape is the convex hull. The idea in this case is to compute the convex hull of each entity based on its contour points and based on this result to compute the minimum distance between bounding shapes and use this, as before, as the minimum distance between the two entities. From now on the algorithm is exactly like the one presented above. It begins by constructing a cluster from an empty set by growing it with the closest entity, in the sense of the minimum distance between the bounding shapes. The algorithm continues to build the other clusters in the same manner, just that now, a cluster can also contain other clusters, if the distance between them is the same order of magnitude. The algorithm finishes and produces a hierarchical model of the page, where the root of the tree represents the entire page; its children represent high level layout elements like paragraphs, images, tables, titles, headings, etc. Their children represent smaller elements like text lines, graphical lines, and so on. The leaves represent the smallest elements, which commonly are characters.




Fig. 4 – simple cluster tree: internal nodes are labeled with the cluster diameters.

„Jobmaschine“

neue Stellen / Opposition: Schönfärberei

ennoch meinte Rexrodt: „liegt hinter uns.“ CDU-Peter Hintze sagte: „Die angesprungen.“

nderungen auf dem Ar- en laut Rexrodt nur ge- wenn die Koalition ihre Das bedeute mehr Wett- Staat, vereinfachte Pla- hmigungsverfahren, grö- und verbesserte Risiko- g. „Eine wirtschaftspoli- wärts — so wie von der schafft keine Arbeitsplät- lt; die „Fahrt ins rot-grü- würde einem „Katastro- e Menschen in Deutsch-

te den Jahreswirtschafts- ment des Starrsinns und igkeit. „Die möglichen Turbulenzen in Südost- hung der Konjunktur in che Zinsanpassungen im mit der Europäischen und die schwache Bin- rden von der Bundesre- gerspielt, anstatt wirt- Vorsorge zu treffen“, kri- llvertretende Fraktions- e Fuchs und der Wirt- rst Schwanhold.

litiker bezeichneten die der Regierung als ge-

scheitert. Sie habe zu immer neuen Rek- korden bei der Arbeitslosigkeit, bei der Staatsverschuldung, bei der Steuer- und Abgabenbelastung sowie bei Pleiten ge- führt. „Da nützt auch die Wahlkampfhilfe der Spitzenrepräsentanten aus den Wirt- schaftsv Verbänden nichts“, so die SPD- Abgeordneten.

Auch die Deutsche Angestellten-Ge- werkschaft (DAG) und der Deutsche Ge- werkschaftsbund (DGB) bezweifeln die vorhergesagte Trendwende. Die Arbeitslo- sigkeit werde vielmehr auf Rekordniveau stagnieren, prophezeite die stellvertreten- de DAG-Vorsitzende Ursula Konitzer. Wichtige Wirtschaftsverbände begrüßten dagegen den Bericht. Der Deutsche Indus- trie- und Handelstag nannte ihn „zutref- fend“, der Bundesverband der Deutschen Banken sprach von einer realistischen Darstellung. Zusammen mit anderen Ver- bänden forderten sie aber weitere Refor- men für ein besseres Investitionsklima.

Der Bundesverband mittelständische Wirtschaft (BVMW) kritisierte unterdes- sen die „überleitete und weitgehend unkriti- sche“ Parteinahme von Spitzenverbänden der Wirtschaft zugunsten der Regierung. BVMW-Hauptgeschäftsführer Dieter Här- the warnte davor, wie die Gewerkschaften ein politisches Lager offen zu unterstüt- zen. Die Wirtschaftsverbände seien schließlich kein „Kanzlerwahlverein“.

Berichte Seite 4 und Wirtschaftsteil

ie Strafe r nicht bewiesen

medizinischen Attesten 1. Sie sprach während des flich von „schlechter Be- straft werden müsse.

nun, daß nach dem Frei- sten die Jugendlichen er- gestellt werden könnten. egen elf der Schüler we- ft in einer terroristischen r ausgesetzt worden, weil e möglicherweise unter gekommen waren. Die ren zu jeweils 15 Jahren orden.

„mittler von amnesty in- than Sugden, forderte in- kation auf den Freispruch egierungen auf, ihren gierung in Ankara zu er- stärker als zuvor zu Ju- drängt werden. Dieses : verrottet“, sagte Sugden Rundschau. Während des seien die Richter sechs- st worden.

st international bereits Folter kritisiert worden. rangenen Woche war ein fanisa bekanntgeworden. nach schweren Mißhand- len, seinen vermißt ht zu haben. Drei Tage ler Vater wieder auf. Er age bei Verwandten ver-

weiterer Bericht S. 4

Öffentlicher Dienst

Schlichter zeigen sich „gemäßigt optimistisch“

stg BREMEN, 11. März. Die beiden Vorsitzenden der Schlichtungskommission für die schwierige Tarifrunde im Öffentlichen Dienst sind nach eigenen Aussagen „gemäßigt optimistisch“, daß sie ein Kompromißpaket schnüren können. Die Tarifparteien seien einigungswillig, sagten Bremens Ex-Bürgermeister Hans Koschnick (SPD) und der frühere Regie- rungshelfer von Rheinland-Pfalz, Carl-Ludwig Wagner (CDU), am Mittwoch nach dem ersten Tag der Schlichtungsgesprä- che in Bremen. Die Verhandlungen sollen am Montag fortgesetzt werden.

Die „allgemein verfolgte Linie“ läuft nach Angaben der Schlichter darauf hin- aus, die Löhne und Gehälter für die 3,2 Millionen Angestellten und Arbeiter von Bund, Ländern und Gemeinden nur ge- ring zu erhöhen, um Arbeitsplätze zu si- chern. Zudem sollen die Ost-Tarife an West-Niveau angeglichen werden. Koschnick und Wagner setzen sich auch da- für ein, steigende Kosten der Alters-Zu- satzversorgung abzufangen. Diese wird bisher nur von den Arbeitgebern finan- ziert. Nach deren Ansicht sollten auch die Beschäftigten Beiträge zahlen.

Die Arbeitgeber haben ein Prozent Lohn- und Gehaltserhöhung angeboten, aber neben dem Zusatzrenten-Beitrag auch Einschnitte bei der Lohnfortzahlung für Kranke und bei Überstundenzuschlä- gen gefordert, was die Gewerkschaften ablehnen. Deren Forderungen würden 4,5 Prozent Mehrausgaben bedeuten.

Fig. 5 - initial image.

„Jobmaschine“

neue Stellen / Opposition: Schönfärberei

ennoch meinte Rexrodt: „liegt hinter uns.“ CDU-Peter Hintze sagte: „Die angesprungen.“

nderungen auf dem Ar- en laut Rexrodt nur ge- wenn die Koalition ihre Das bedeute mehr Wett- Staat, vereinfachte Pla- hmigungsverfahren, grö- und verbesserte Risiko- g. „Eine wirtschaftspoli- wärts — so wie von der schafft keine Arbeitsplät- lt; die „Fahrt ins rot-grü- würde einem „Katastro- e Menschen in Deutsch-

te den Jahreswirtschafts- ment des Starrsinns und igkeit. „Die möglichen Turbulenzen in Südost- hung der Konjunktur in che Zinsanpassungen im mit der Europäischen und die schwache Bin- rden von der Bundesre- gerspielt, anstatt wirt- Vorsorge zu treffen“, kri- llvertretende Fraktions- e Fuchs und der Wirt- rst Schwanhold.

litiker bezeichneten die der Regierung als ge-

Berichte Seite 4 und Wirtschaftsteil

ie Strafe r nicht bewiesen

medizinischen Attesten 1. Sie sprach während des flich von „schlechter Be- straft werden müsse.

nun, daß nach dem Frei- sten die Jugendlichen er- gestellt werden könnten. egen elf der Schüler we- ft in einer terroristischen r ausgesetzt worden, weil e möglicherweise unter gekommen waren. Die ren zu jeweils 15 Jahren orden.

„mittler von amnesty in- than Sugden, forderte in- kation auf den Freispruch egierungen auf, ihren gierung in Ankara zu er- stärken als zuvor zu Ju- drängt werden. Dieses : verrottet“, sagte Sugden Rundschau. Während des seien die Richter sechs- st worden.

st international bereits Folter kritisiert worden. rangenen Woche war ein fanisa bekanntgeworden. nach schweren Mißhand- len, seinen vermißt ht zu haben. Drei Tage ler Vater wieder auf. Er age bei Verwandten ver-

weiterer Bericht S. 4

scheitert. Sie habe zu immer neuen Rek- korden bei der Arbeitslosigkeit, bei der Staatsverschuldung, bei der Steuer- und Abgabenbelastung sowie bei Pleiten ge- führt. „Da nützt auch die Wahlkampfhilfe der Spitzenrepräsentanten aus den Wirt- schaftsv Verbänden nichts“, so die SPD- Abgeordneten.

Auch die Deutsche Angestellten-Ge- werkschaft (DAG) und der Deutsche Ge- werkschaftsbund (DGB) bezweifeln die vorhergesagte Trendwende. Die Arbeitslo- sigkeit werde vielmehr auf Rekordniveau stagnieren, prophezeite die stellvertreten- de DAG-Vorsitzende Ursula Konitzer. Wichtige Wirtschaftsverbände begrüßten dagegen den Bericht. Der Deutsche Indus- trie- und Handelstag nannte ihn „zutref- fend“, der Bundesverband der Deutschen Banken sprach von einer realistischen Darstellung. Zusammen mit anderen Ver- bänden forderten sie aber weitere Refor- men für ein besseres Investitionsklima.

Der Bundesverband mittelständische Wirtschaft (BVMW) kritisierte unterdes- sen die „überleitete und weitgehend unkriti- sche“ Parteinahme von Spitzenverbänden der Wirtschaft zugunsten der Regierung. BVMW-Hauptgeschäftsführer Dieter Här- the warnte davor, wie die Gewerkschaften ein politisches Lager offen zu unterstüt- zen. Die Wirtschaftsverbände seien schließlich kein „Kanzlerwahlverein“.

Berichte Seite 4 und Wirtschaftsteil

Öffentlicher Dienst

Schlichter zeigen sich „gemäßigt optimistisch“

stg BREMEN, 11. März. Die beiden Vorsitzenden der Schlichtungskommission für die schwierige Tarifrunde im Öffentlichen Dienst sind nach eigenen Aussagen „gemäßigt optimistisch“, daß sie ein Kompromißpaket schnüren können. Die Tarifparteien seien einigungswillig, sagten Bremens Ex-Bürgermeister Hans Koschnick (SPD) und der frühere Regie- rungshelfer von Rheinland-Pfalz, Carl-Ludwig Wagner (CDU), am Mittwoch nach dem ersten Tag der Schlichtungsgesprä- che in Bremen. Die Verhandlungen sollen am Montag fortgesetzt werden.

Die „allgemein verfolgte Linie“ läuft nach Angaben der Schlichter darauf hin- aus, die Löhne und Gehälter für die 3,2 Millionen Angestellten und Arbeiter von Bund, Ländern und Gemeinden nur ge- ring zu erhöhen, um Arbeitsplätze zu si- chern. Zudem sollen die Ost-Tarife an West-Niveau angeglichen werden. Koschnick und Wagner setzen sich auch da- für ein, steigende Kosten der Alters-Zu- satzversorgung abzufangen. Diese wird bisher nur von den Arbeitgebern finan- ziert. Nach deren Ansicht sollten auch die Beschäftigten Beiträge zahlen.

Die Arbeitgeber haben ein Prozent Lohn- und Gehaltserhöhung angeboten, aber neben dem Zusatzrenten-Beitrag auch Einschnitte bei der Lohnfortzahlung für Kranke und bei Überstundenzuschlä- gen gefordert, was die Gewerkschaften ablehnen. Deren Forderungen würden 4,5 Prozent Mehrausgaben bedeuten.

Fig. 6 - image obtained after applying Delaunay triangulation.

Fig. 5 and Fig. 6 represent two versions of the same image before and after the Delaunay triangulation. The first image contains the unaltered document page, while the second one is the result of applied Delaunay after taking into account the bounding shape.

As it can be seen, entities are connected one to another by a thick collection of edges, which are all drawn with the same color in order to emphasize the unity of these lines. Each color contains only the connections between the points on the bounding shape of only two entities and so, it provides a good visual measurement of the distances.

Form the entire collection of connections only the smallest distance is selected and taken as input into the algorithm.

A. *Hierarchy Model – Cluster tree*

As described, a cluster tree can be constructed to model the page hierarchy. In this tree all the leaves represent the input data, the entities. The leaves are grouped into clusters; each cluster is represented by a tree node which is labeled with the diameter of the cluster.

The idea of the cluster tree is that any two elements inside a cluster have a distance no more than the cluster diameter. This also means that each sub-tree of the structure is a cluster in which all of the nodes are closer to each other than to any other node outside that cluster. Fig. 7 shows an example of a cluster tree structure.

As it can be seen in the example, the diameters of the clusters increase if traversing the tree from bottom to top. Each node is included in exactly one cluster and it has no children. The labels of the non-leaf nodes seen in the example represent the maximum distances inside each cluster, or the cluster diameter. For example the cluster “ab” composed of the entities “a” and “b” has the maximum distance 20, which means that no entities inside this cluster are more than 20 units apart. Also, as stated in the definition of the cluster tree and as an implicit effect of the construction algorithm, there is no node lying less than 21 units from either “a” or “b”.




Fig. 7: an example of Cluster Tree

In this example, the order of magnitude is thought to be different if the diameters are not equal. Practical implementations use a threshold to establish if two entities can be part of the same cluster.

In the context of layout analysis, when talking about the distance between two entities we shall actually be referring to the diameter of the cluster that those entities are part of. This will be referred to as the *hierarchy distance*, and it is opposed to the *Euclidian distance*. The *Euclidian distance* is used to build the cluster tree, while the *hierarchy distance* is used as a layout space measure.

The Euclidian distance is a well-known term which defines the minimal path between two points, the length of the segment that connects them. The hierarchy distance however has a different meaning. In the following example the distance between the points “A” and “D” is 90.




Fig. 8: the meaning of hierarchy distance

The hierarchy distance between “A” and “D” is 45 and can be obtained from the cluster tree. Because “B” and “C” form a cluster and then join with “A” into another cluster before joining with “D” all three points have the same hierarchy distance to “D”, which is the Euclidian distance between “C” and “D”. And so, this new measurement unit provides a good mean of evaluating cluster closure.

Now that the terms used in this paper have been explained there are several steps that have to be followed in order to obtain the desired clusters. The first step was to create the cluster tree. Next, the information contained in the clusters is used to join different entities or groups of entities depending on hierarchy distances. In the following group of images the creation of the clusters can be observed and the final result of splitting the document in zones with similar characteristics is obtained.

Die Bundesregierung sagt voraus, daß es 1998 ein Wirtschaftswachstum von bis zu drei Prozent und am Jahresende weniger Arbeitslose geben wird. So steht es im Jahreswirtschaftsbericht, den das Kabinett am Mittwoch verabschiedete. Die Opposition sprach von „Schönfärberei“, Gewerkschaften vom „Prinzip Hoffnung“.

Fig. 9: one of the first steps of the algorithm where there exists a large number of clusters because of the small minimal value of edges connected so far.

As it can be seen this is the first iteration of the process where only the closest entities were connected into clusters. To have a better view on the clustering, only a small part of the initial picture has been taken for the first set of result images and the clusters have been bounded with rectangles. For a picture of such sizes this has almost no effect and does not provide any aid in splitting the document in zones. The next picture however is taken after only a few more iterations. It can be observed that groups of entities have been connected by the algorithm and some sort of cluster hierarchy has been created.

Die Bundesregierung sagt voraus, daß es 1998 ein Wirtschaftswachstum von bis zu drei Prozent und am Jahresende weniger Arbeitslose geben wird. So steht es im Jahreswirtschaftsbericht, den das Kabinett am Mittwoch verabschiedete. Die Opposition sprach von „Schönfärberei“, Gewerkschaften vom „Prinzip Hoffnung“.

Fig. 10: the information inside the clusters is starting to create some sort of hierarchy.

By continuing the process of joining the clusters the presented paragraph of the initial image has been finally detected as an independent zone.

Die Bundesregierung sagt voraus, daß es 1998 ein Wirtschaftswachstum von bis zu drei Prozent und am Jahresende weniger Arbeitslose geben wird. So steht es im Jahreswirtschaftsbericht, den das Kabinett am Mittwoch verabschiedete. Die Opposition sprach von „Schönfärberei“, Gewerkschaften vom „Prinzip Hoffnung“.

Fig. 11: the paragraph has been included into a single cluster.

In the end all the zones have been detected properly. The iteration process of joining clusters can continue and the whole page will be seen as a standalone cluster, but this would be too much. The purpose is to create zones of similar information in the page and after a number of iterations that algorithm must stop.

The charts provide an overview of the distance values for the current tested image by plotting the histograms of such values.

The result obtained for the given picture allows the detection of titles, paragraphs and even articles. However without a mechanism for result measurement there is no knowing when to stop the iteration process.

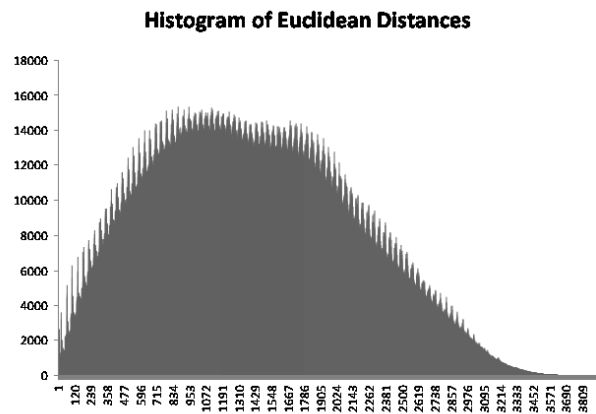


Fig. 12: the histogram of the Euclidian distances inside the image.

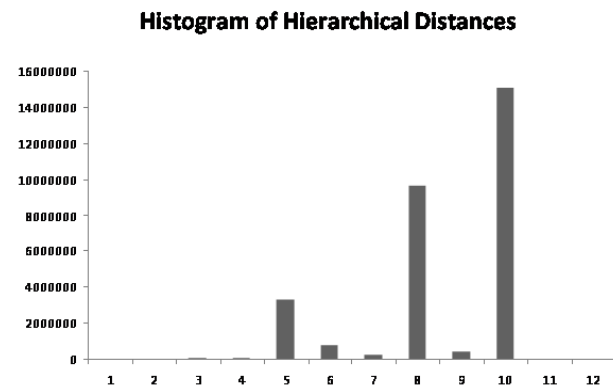


Fig. 13: the histogram of the hierarchical distances computed for the input image.

For this purpose several concepts will be introduced. First of all by joining the entities there is one measure that always changes making each iteration different from all others. By using this knowledge a mechanism for assessing the results and finding the steps in which a relevant change has been made can be developed.

CDU beschwört „Jobmaschine“

Bundesregierung prophezeit **200.000 neue Stellen** / **Opposition:** Schönfärberei

Von Rolf Dietrich Schwarz

Die Bundesregierung sagt voraus, daß bis 1998 ein Wirtschaftswachstum von bis zu drei Prozent und am Jahresende weniger Arbeitslose geben wird. So steht es im Jahreswirtschaftsbericht, den das Kabinett am Mittwoch verabschiedete. Die Opposition sprach von „Schönfärberei“. Gewerkschaften vom „Prinzip Hoffnung“.

BONN, 11. März. Die Bundesregierung rechnet in ihrem Jahreswirtschaftsbericht damit, daß bis zum Jahresende 200.000 zusätzliche Arbeitsplätze geschaffen werden. Diese Schätzung liegt weit unter den Versprechen der Wirtschaftsverbände, die 500.000 bis 600.000 neue Stellen angekündigt haben. Bundeskanzler Helmut Kohl (CDU) hatte sich diesem Optimismus angeschlossen. Das Kabinett billigte zudem den Sozialbericht, wonach die Sozialleistungen in den nächsten drei Jahren auf den Stand von Ende der 60er Jahre schrumpfen werden.

Wirtschaftsminister Günter Rexrodt (FDP) prognostizierte, in Westdeutschland werde es zum Jahresende rund 100.000 Arbeitslose weniger geben. Ähnliches könne im Osten erreicht werden. Allerdings bezieht sich die Annahme nur auf die Rechnung von einem Jahresende zum anderen — im Jahresschnitt bleibt die Arbeitslosenquote demnach unverändert bei 11,5 Prozent. Dennoch meinte Rexrodt: „Das Schlimmste liegt hinter uns.“ CDU-Generalsekretär Peter Hintze sagte: „Die Jobmaschine ist angesprungen.“

Die Herausforderungen auf dem Arbeitsmarkt können laut Rexrodt nur gemeistert werden, wenn die Koalition ihre Politik fortsetze. Das bedeute mehr Wettbewerb, weniger Staat, vereinfachte Planungs- und Genehmigungsverfahren, größere Flexibilität und verbesserte Risikokapitalversorgung. „Eine wirtschaftspolitische Rolle rückwärts — so wie von der SPD geplant — schafft keine Arbeitsplätze“, sagte Rexrodt; die „Fahrt ins rot-grüne Traumland“ würde einem „Katastrophen-Trip für die Menschen in Deutschland“ gleichen.

Die SPD nannte den Jahreswirtschaftsbericht ein Dokument des Starrsinns und der Uneinsichtigkeit. „Die möglichen Spätfolgen der Turbulenzen in Südostasien, die Abflachung der Konjunktur in den USA, mögliche Zinsanpassungen im Zusammenhang mit der Europäischen Währungsunion und die schwache Binnenachfrage werden von der Bundesregierung heruntergespielt, anstatt wirtschaftspolitische Vorsorge zu treffen“, kritisierte die stellvertretende Fraktionsvorsitzende Anke Fuchs und der Wirtschaftsexperte Ernst Schwanhold.

Beide SPD-Politiker bezeichneten die Angebotspolitik der Regierung als gescheitert. Sie habe zu immer neuen Rekorden bei der Arbeitslosigkeit, bei der Staatsverschuldung, bei der Steuer- und Abgabenbelastung sowie bei Pleiten geführt. „Da nützt auch die Wahlkampfhilfe der Spitzenrepräsentanten aus den Wirtschaftsverbänden nichts“, so die SPD-Abgeordneten.

Auch die Deutsche Angestellten-Gewerkschaft (DAG) und der Deutsche Gewerkschaftsbund (DGB) bezweifeln die vorhergesagte Trendwende. Die Arbeitslosigkeit werde vielmehr auf Rekordniveau stagnieren, prophezeite die stellvertretende DAG-Vorsitzende Ursula Konitzer. Wichtige Wirtschaftsverbände begrüßten dagegen den Bericht. Der Deutsche Industrie- und Handelstag nannte ihn „zutreffend“, der Bundesverband der Deutschen Banken sprach von einer realistischen Darstellung. Zusammen mit anderen Verbänden forderten sie aber weitere Reformen für ein besseres Investitionsklima.

Der Bundesverband mittelständische Wirtschaft (BVMW) kritisierte indes den „überheulenden und weitgehend unkritische“ Parteinahme von Spitzenverbänden der Wirtschaft zugunsten der Regierung. BVMW-Hauptgeschäftsführer Dieter Härthe warnte davor, wie die Gewerkschaften ein politisches Lager offen zu unterstützen. Die Wirtschaftsverbände seien schließlich kein „Kanzlerwahlverein“.

Berichte Seite 4 und Wirtschaftsteil

Türkische Polizisten ohne Strafe

Gericht in Manisa nennt Vorwurf der Folter nicht bewiesen

Von Gunnar Kohne

ISTANBUL, 11. März. Das Strafgericht in der westtürkischen Stadt Manisa hat am Mittwoch zehn Polizisten von dem Vorwurf freigesprochen, sie hätten 16 Jugendliche gefoltert. Dafür gebe es keine hinlänglichen Beweise, hieß es in der Begründung. Einer der Anwälte der Jugendlichen, der sozialdemokratische Abgeordnete Sabri Ergül, sprach von einem „Schock“ und kündigte Berufung gegen das Urteil an. Es müsse sich um einen Justizirrtum handeln.

Die Schüler waren im Dezember 1995 unter dem Verdacht der Mitgliedschaft in einer linksgerichteten militanten Organisation eine Woche lang in der Polizeizentrale von Manisa festgehalten worden. Dort wurden sie nach eigenen Angaben nackt ausgezogen, mit kaltem Wasser abgespritzt und unter anderem an den Genitalien mit Elektroschocks gefoltert. Der damals 14jährige Mahir Göktaş gab später zu Protokoll: „Sie versetzten mir Stromstöße am rechten Daumen, an meinen Armen, in der Bauchgegend und an meinen Sexualorganen. Danach hatte ich in meinem rechten Fuß und meinen Genitalien überhaupt kein Gefühl mehr.“

Ergül hatte die Jugendlichen bei einem unangemeldeten Besuch der Polizeistation zum Teil nackt und mit verbundenen Augen vorgefunden. Doch selbst die Staatsanwaltschaft ließ sich von den Aussagen des Parlamentsmitglieds und von

ten zahlreichen medizinischen Attesten nicht überzeugen. Sie sprach während des Verfahrens lediglich von „schlechter Behandlung“, die bestraft werden müsse.

Ergül fürchtet nun, daß nach dem Freispruch der Polizisten die Jugendlichen erneut vor Gericht gestellt werden könnten. Das Verfahren gegen elf der Schüler wegen Mitgliedschaft in einer terroristischen Organisation war ausgesetzt worden, weil die Geständnisse möglicherweise unter Folter zustande gekommen waren. Die übrigen fünf waren zu jeweils 15 Jahren Haft verurteilt worden.

Der Türkei-Ermittler von amnesty international, Jonathan Sugden, forderte in einer ersten Reaktion auf den Freispruch ausländische Regierungen auf, ihren Druck auf die Regierung in Ankara zu erhöhen. „Sie muß stärker als zuvor zu Justizreformen gedrängt werden. Dieses System ist völlig verrottet“, sagte Sugden der Frankfurter Rundschau. Während des Folterprozesses seien die Richter sechsmal ausgewechselt worden.

Die Türkei ist international bereits mehrfach wegen Folter kritisiert worden. Erst in der vergangenen Woche war ein neuer Fall in Manisa bekanntgeworden. Ein Mann hatte nach schweren Mißhandlungen gestanden, seinen vermißten Vater umgebracht zu haben. Drei Tage später tauchte der Vater wieder auf. Er hatte ein paar Tage bei Verwandten verbracht.

Kommentar S. 3, weiterer Bericht S. 4

Öffentlicher Dienst

Schlichter zeigen sich „gemäßigt optimistisch“

stg BREMEN, 11. März. Die beiden Vorsitzenden der Schlichtungskommission für die schwierige Tarifrunde im Öffentlichen Dienst sind nach eigenen Aussagen „gemäßigt optimistisch“, daß sie ein Kompromißpaket schnüren können. Die Tarifparteien seien einigungswillig, sagten Bremens Ex-Bürgermeister Hans Koschnick (SPD) und der frühere Regierungschef von Rheinland-Pfalz, Carl-Ludwig Wagner (CDU), am Mittwoch nach dem ersten Tag der Schlichtungsgespräche in Bremen. Die Verhandlungen sollen am Montag fortgesetzt werden.

Die „allgemein verfolgte Linie“ läuft nach Angaben der Schlichter darauf hinaus, die Löhne und Gehälter für die 3,2 Millionen Angestellten und Arbeiter von Bund, Ländern und Gemeinden um gering zu erhöhen, um Arbeitsplätze zu sichern. Zudem sollen die Ost-Tarife an West-Niveau angeglichen werden. Koschnick und Wagner setzen sich auch dafür ein, steigende Kosten der Alters-Zusatzversorgung abzufangen. Diese wird bisher nur von den Arbeitgebern finanziert. Nach deren Ansicht sollten auch die Beschäftigten Beiträge zahlen.

Die Arbeitgeber haben um Prozent Lohn- und Gehaltserhöhung angeboten, aber neben dem Zusatzrenten-Beitrag auch Einschnitte bei der Lohnfortzahlung für Kranke und bei Überstundenzuschlägen gefordert, was die Gewerkschaften ablehnen. Deren Forderungen würden 4,5 Prozent Mehrausgaben bedeuten.

Fig. 14: an overview of the image at the step where the presented paragraph is found as an individual cluster.

Therefore the most important thing that changes with each iteration and provides relevant information on the clusters is the rectangular area of the clusters.

This can be divided into three different types: total rectangular area (the sum of all the areas of the rectangles that bind the clusters); overlapping rectangle area (the sum of all the rectangles that result from the intersection of all the

rectangles that bind the clusters), non-overlapping rectangular area (the sum of all the areas of the rectangles that bind the clusters from which the overlapping area is subtracted). The above charts present the measurement stated above at each iteration.

From these results we can determine the inflexion points, the points in the graph where the function changes its slope

sign. These points are represented with a white line in the graph. In this case the function is the type of area used for the chart.

By evaluating these results it can be stated that at each inflexion point there has been an important change in the

graph. For example, when the next value of the total area is higher than the current one this means that the clusters have been joined together into a bigger one.

CDU beschwört „Jobmaschine“

Bundesregierung prophezeit 200 000 neue Stellen / Opposition: Schönfärberei

Von Rolf Dietrich Schwartz
Die Bundesregierung sagt voraus, daß es 1998 ein Wirtschaftswachstum von bis zu drei Prozent und am Jahresende weniger Arbeitslose geben wird. So steht es im Jahreswirtschaftsbericht, den das Kabinett am Mittwoch verabschiedete. Die Opposition sprach von „Schönfärberei“, Gewerkschaften vom „Prinzip Hoffnung“.

BONN, 11. März. Die Bundesregierung rechnet in ihrem Jahreswirtschaftsbericht damit, daß bis zum Jahresende 200 000 zusätzliche Arbeitsplätze geschaffen werden. Diese Schätzung liegt weit unter den Versprechen der Wirtschaftsverbände, die 500 000 bis 600 000 neue Stellen angekündigt haben. Bundeskanzler Helmut Kohl (CDU) hatte sich diesem Optimismus angeschlossen. Das Kabinett billigte zudem den Sozialbericht, wonach die Sozialleistungen in den nächsten drei Jahren auf den Stand von Ende der 60er Jahre schrumpfen werden.

Wirtschaftsminister Günter Rexrodt (FDP) prognostizierte, in Westdeutschland werde es zum Jahresende rund 100 000 Arbeitslose weniger geben. Ähnliches könne im Osten erreicht werden. Allerdings bezieht sich die Annahme nur auf die Rechnung von einem Jahresende zum anderen — im Jahresschnitt bleibt die Arbeitslosenquote demnach unverändert bei

11,5 Prozent. Dennoch meinte Rexrodt: „Das Schlimmste liegt hinter uns.“ CDU-Generalsekretär Peter Hintze sagte: „Die Jobmaschine ist angesprungen.“

Die Herausforderungen auf dem Arbeitsmarkt können laut Rexrodt nur gemeistert werden, wenn die Koalition ihre Politik fortsetze. Das bedeute mehr Wettbewerb, weniger Staat, vereinfachte Planungs- und Genehmigungsverfahren, größere Flexibilität und verbesserte Risikokapitalversorgung. „Eine wirtschaftspolitische Rolle rückwärts — so wie von der SPD geplant — schafft keine Arbeitsplätze“, sagte Rexrodt; die „Fahrt ins rot-grüne Traumland“ würde einem „Katastrophen-Trip für die Menschen in Deutschland“ gleichen.

Die SPD nannte den Jahreswirtschaftsbericht ein Dokument des Starrsinns und der Uneinsichtigkeit. „Die möglichen Spätfolgen der Turbulenzen in Südostasien, die Abflachung der Konjunktur in den USA, mögliche Zinsanpassungen im Zusammenhang mit der Europäischen Währungsunion und die schwache Binnennachfrage werden von der Bundesregierung heruntergespielt, anstatt wirtschaftspolitische Vorsorge zu treffen“, kritisierten die stellvertretende Fraktionsvorsitzende Anke Fuchs und der Wirtschaftsexperte Ernst Schwannhold.

Beide SPD-Politiker bezeichneten die Angebotspolitik der Regierung als ge-

scheitert. Sie habe zu immer neuen Rekorde bei der Arbeitslosigkeit, bei der Staatsverschuldung, bei der Steuer- und Abgabenbelastung sowie bei Pleiten geführt. „Da nützt auch die Wahlkampfhilfe der Spitzenrepräsentanten aus den Wirtschaftsverbänden nichts“, so die SPD-Abgeordneten.

Auch die Deutsche Angestellten-Gewerkschaft (DAG) und der Deutsche Gewerkschaftsbund (DGB) bezweifeln die vorhergesagte Trendwende. Die Arbeitslosigkeit werde vielmehr auf Rekordniveau stagnieren, prophezeite die stellvertretende DAG-Vorsitzende Ursula Konitzer. Wichtige Wirtschaftsverbände begrüßten dagegen den Bericht. Der Deutsche Industrie- und Handelstag nannte ihn „zutreffend“, der Bundesverband der Deutschen Banken sprach von einer realistischen Darstellung. Zusammen mit anderen Verbänden forderten sie aber weitere Reformen für ein besseres Investitionsklima.

Der Bundesverband mittelständische Wirtschaft (BVMW) kritisierte unterdessen die „überreilte und weitgehend unkritische“ Parteinahme von Spitzenverbänden der Wirtschaft zugunsten der Regierung. BVMW-Hauptgeschäftsführer Dieter Harthe warnte davor, wie die Gewerkschaften ein politisches Lager offen zu unterstützen. Die Wirtschaftsverbände seien schließlich kein „Kanzlerwahlverein“.

Berichte Seite 4 und Wirtschaftsteil

Türkische Polizisten ohne Strafe

Gericht in Manisa nennt Vorwurf der Folter nicht bewiesen

Von Gunnar Köhne

ISTANBUL, 11. März. Das Strafgericht in der westtürkischen Stadt Manisa hat am Mittwoch zehn Polizisten von dem Vorwurf freigesprochen, sie hätten 16 Jugendliche gefoltert. Dafür gebe es keine hinlänglichen Beweise, hieß es in der Begründung. Einer der Anwälte der Jugendlichen, der sozialdemokratische Abgeordnete Sabri Ergül, sprach von einem „Schock“ und kündigte Berufung gegen das Urteil an. Es müsse sich um einen Justizirrtum handeln.

Die Schüler waren im Dezember 1995 unter dem Verdacht der Mitgliedschaft in einer linksgerichteten militanten Organisation eine Woche lang in der Polizeizentrale von Manisa festgehalten worden. Dort wurden sie nach eigenen Angaben nackt ausgezogen, mit kaltem Wasser abgespritzt und unter anderem an den Genitalien mit Elektroschocks gefoltert. Der damals 14jährige Mahir Göktaş gab später zu Protokoll: „Sie versetzten mir Stromstöße am rechten Daumen, an meinen Armen, in der Bauchgegend und an meinen Sexualorganen. Danach hatte ich in meinem rechten Fuß und meinen Genitalien überhaupt kein Gefühl mehr.“

Ergül hatte die Jugendlichen bei einem unangemeldeten Besuch der Polizeistation zum Teil nackt und mit verbundenen Augen vorgefunden. Doch selbst die Staatsanwaltschaft ließ sich von den Aussagen des Parlamentsmitglieds und von

den zahlreichen medizinischen Attesten nicht überzeugen. Sie sprach während des Verfahrens lediglich von „schlechter Behandlung“, die bestraft werden müsse.

Ergül fürchtet nun, daß nach dem Freispruch der Polizisten die Jugendlichen erneut vor Gericht gestellt werden könnten. Das Verfahren gegen elf der Schüler wegen Mitgliedschaft in einer terroristischen Organisation war ausgesetzt worden, weil die Geständnisse möglicherweise unter Folter zustande gekommen waren. Die übrigen fünf waren zu jeweils 15 Jahren Haft verurteilt worden.

Der Türkei-Ermittler von amnesty international, Jonathan Sugden, forderte in einer ersten Reaktion auf den Freispruch ausländische Regierungen auf, ihren Druck auf die Regierung in Ankara zu erhöhen. „Sie muß stärker als zuvor zu Justizreformen gedrängt werden. Dieses System ist völlig verrotten“, sagte Sugden der *Frankfurter Rundschau*. Während des Folterprozesses seien die Richter sechsmal ausgewechselt worden.

Die Türkei ist international bereits mehrfach wegen Folter kritisiert worden. Erst in der vergangenen Woche war ein neuer Fall in Manisa bekanntgeworden. Ein Mann hatte nach schweren Mißhandlungen gestanden, seinen vermißten Vater umgebracht zu haben. Drei Tage später tauchte der Vater wieder auf. Er hatte ein paar Tage bei Verwandten verbracht.

Kommentar S. 3, weiterer Bericht S. 4

Öffentlicher Dienst

Schlichter zeigen sich „gemäßigt optimistisch“

stg BREMEN, 11. März. Die beiden Vorsitzenden der Schlichtungskommission für die schwierige Tarifrunde im Öffentlichen Dienst sind nach eigenen Aussagen „gemäßigt optimistisch“, daß sie ein Kompromißpaket schnüren können. Die Tarifparteien seien einigungswillig, sagten Bremens Ex-Bürgermeister Hans Koschnick (SPD) und der frühere Regierungschef von Rheinland-Pfalz, Carl-Ludwig Wagner (CDU), am Mittwoch nach dem ersten Tag der Schlichtungsgespräche in Bremen. Die Verhandlungen sollen am Montag fortgesetzt werden.

Die „allgemein verfolgte Linie“ läuft nach Angaben der Schlichter darauf hinaus, die Löhne und Gehälter für die 3,2 Millionen Angestellten und Arbeiter von Bund, Ländern und Gemeinden nur gering zu erhöhen, um Arbeitsplätze zu sichern. Zudem sollen die Ost-Tarife an West-Niveau angeglichen werden. Koschnick und Wagner setzen sich auch dafür ein, steigende Kosten der Alters-Zusatzversorgung abzufangen. Diese wird bisher nur von den Arbeitgebern finanziert. Nach deren Ansicht sollten auch die Beschäftigten Beiträge zahlen.

Die Arbeitgeber haben ein Prozent Lohn- und Gehaltserhöhung angeboten, aber neben dem Zusatzrenten-Beitrag auch Einschnitte bei der Lohnfortzahlung für Kranke und bei Überstundenzuschlägen gefordert, was die Gewerkschaften ablehnen. Deren Forderungen würden 4,5 Prozent Mehrausgaben bedeuten.

Fig. 15: the final result which finds all the important zones of the page inside an individual cluster

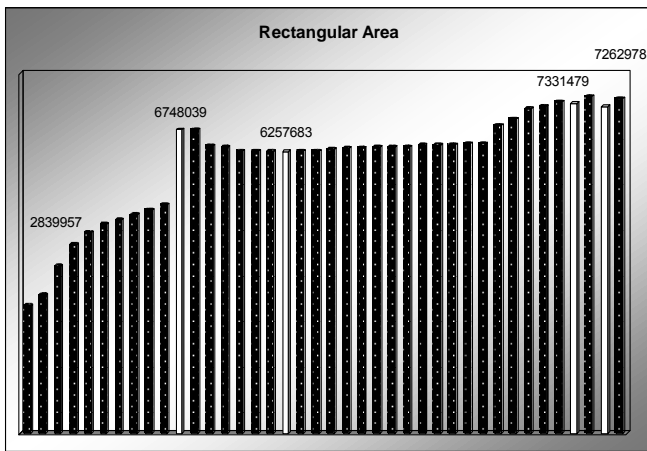


Fig. 16: the rectangular area values chart of the tested image for all iterations.

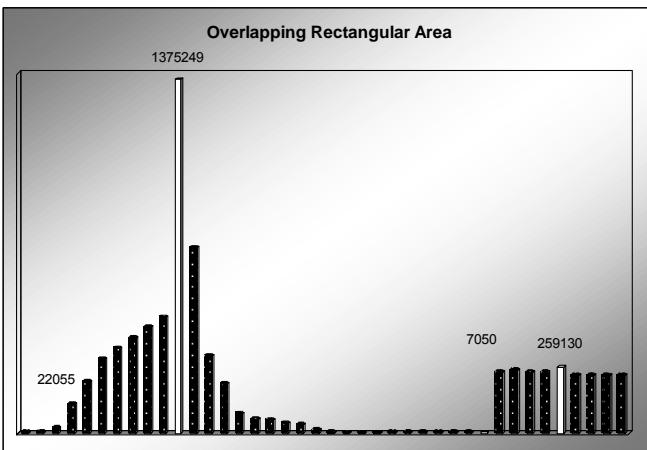


Fig. 17: the overlapping rectangular area values chart of the tested image for all iterations.

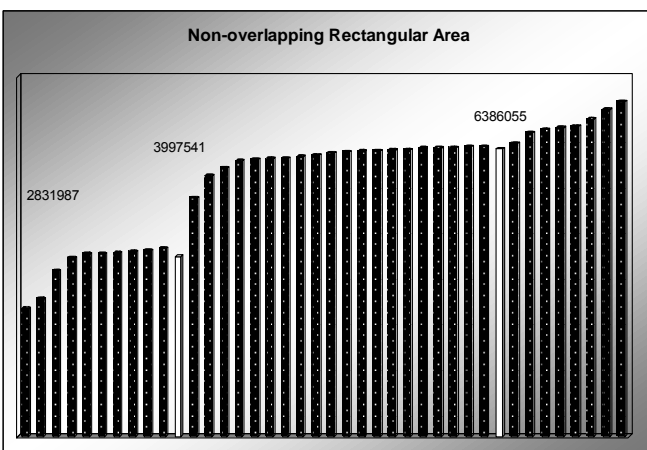


Fig. 18: the non-overlapping rectangular area values chart of the tested image for all iterations.

However, when the next value is lower than the current one some clusters that were inside a bigger one have been

connected to that one and so the area has decreased. By monitoring the changes in slope sign from increase to decrease and decrease to increase it can be observed that the most important changes happen only at those times. And so a decision to stop at a given iteration has to be made taking into accounts only these points. In order to obtain the best cluster hierarchy one of the last such points has to be considered as the stopping point of the algorithm.




Fig. 19: example of using the rectangular area measurement.

In the Fig. 19, the total rectangular area has the value 20, the overlapping rectangular areas has the value 4 and the non-overlapping area has the value 11 because in the given example we assumed that every rectangle has an area equal to 4 units (2 by 2).

IV. CONCLUSION

The approach presented above reveals a good tool for page layout analyze by allowing the selection of different groups of entities. This is done by cutting the tree at different levels and so obtaining the corresponding groups. Such a method allows the correct detection of paragraphs, headlines and other types of layout elements with a simple and easy to implement algorithm that can also have various applications outside the document content conversion area.

By using various mathematical solutions and algorithms together with common knowledge content analyze the correctness of such an approach can be easily proved and verified.

The layout analysis method presented in this paper is a natural development of a hierarchical clustering process. Imagine that you look at a document and, progressively, you slowly move away while continue to look at the document.

What will happen: the image will become kind of “blurry”, you will miss some details of the image, you will not be able to read words from normal text paragraphs but you will still be able to see where the paragraphs, headlines, tables and images are placed and how the document is structured.

Moving farther away of the document will enable you to see less of the document detail but more of the document layout upper-structure. Is something that may be somehow simulated by applying a pyramidal resampling of the image until the image implodes itself in only one dot. This intuitive process is mathematically shaped using the Delaunay triangulation structures to ensure that no precision is lost during different resampling levels and in fact the grouping (clustering) of elements will match the exact behavior of the human eye when increasing viewing distance from the document.

Furthermore, the human eye is more sensitive to rectangular-like structures and, as a result, the rectangular reconstruction of clusters inside the document is favored through the usage of some cluster-area functions that needs local maximization:

- sum of the rectangular areas of the elements;
- sum of the rectangular areas of the elements, excluding rectangular overlaps;
- sum of the rectangular overlaps of the elements.

Having multiple clustering-measures will enable the clustering algorithm to choose the best approach for the current document layout.

ACKNOWLEDGMENT

We want to thank our colleagues from the University “Politehnica” of Bucharest, to the staff of “Computer Science and Engineering” department, for their ideas, research support and useful advices.

REFERENCES

[1] Costin-Anton Boiangiu, Andrei-Iulian Dvornic, “Bitonal image creation for automatic content conversion”, Proceedings of the 9th WSEAS International Conference on Automation and Information, Bucharest, Romania, June 2008, pp. 454-459. W.-K. Chen, *Linear Networks and Systems* (Book style). Belmont, CA: Wadsworth, 1993, pp. 123-135.

[2] Costin-Anton Boiangiu, Bogdan Raducanu “Robust line detection methods”, Proceedings of the 9th WSEAS International Conference on Automation and Information, Bucharest, Romania, June 2008, pp. 464-467.

[3] Moh’d Belal Al-Zoubi, Amjad Hudaib, Bashar Al-Shboul, “A fast fuzzy clustering algorithm”, Proceedings of the 6th WSEAS International Conference on Artificial Intelligence, Knowledge Engineering and Data Bases, Corfu Island, Greece, February 2007, pp. 28-32.

[4] Costin-Anton Boiangiu, Dan-Cristian Cananau, Spataru Andrei, “Detection of arbitrary-form separators based on filtered Delaunay triangulation”, Proceedings of the 9th WSEAS International Conference on Automation and Information, Bucharest, Romania, June 2008, pp. 442-445.

[5] Juan Zapata, Ramon Ruiz, “A hybrid snake for selective contour detection”, Proceedings of the 6th WSEAS International Conference on

Signal Processing, Robotics and Automation, Corfu Island, Greece, February 2007, pp. 230-235.

[6] Yi Xiao, Hong Yan, “Location of title and author regions in document images based on the Delaunay triangulation”, *Image and Vision Computing*, Volume 2, Number 4, April 2004

[7] Jonathan Richard Shewchuck, “Constrained Delaunay tetrahedralization, bistellar flips and provably good boundary recover”, University of California at Berkeley Course Notes.

[8] Jonathan Richard Shewchuck, “Delaunay refinement algorithms for triangular mesh generation”, *Computational Geometry: Theory and Applications*, Volume 22, May 2002.

[9] Steven Fortune, “Voronoi diagrams and Delaunay triangulations”, *Handbook of discrete and computational geometry*, CRC Press, 1997, pp. 377-388.

[10] Jonathan Richard Shewchuck, “Tetrahedral mesh generation by Delaunay refinement”, Proceedings of the Fourteenth Annual Symposium on Computational Geometry, Association for Computing Machinery, Minneapolis, Minnesota, June 1998, pp. 86-95

[11] Liu Wenyin, Dov Dori, “A protocol for performance evaluation of line detection algorithms”, *Machine Vision And Applications*, Volume 9, Numbers 5-6, Springer Berlin / Heidelberg, March 1997, pp. 240-250.

[12] D. S. Guru, B. H. Shekar, P. Nagabhushan, “A simple and robust line detection algorithm based on small eigenvalue analysis”, *Pattern Recognition Letters*, Volume 25, Elsevier Science, 2004.

[13] Steve Mann, “Intelligent image processing”, John Wiley & Sons, 2002.

[14] William K. Pratt, “Digital image processing”, John Wiley & Sons, 2002.

[15] Costin-Anton Boiangiu, “Multimedia techniques”, Macarie Publishing House, 2002.

[16] Costin-Anton Boiangiu, “Elements of virtual reality”, Macarie Publishing House, 2002.

[17] Costin-Anton Boiangiu, “The beta-shape algorithm for polygonal contour reconstruction”, The 14th International Conference on Control System and Computer Science, position C.6. Volume II, Bucharest, July 2003.

[18] Serban Petrescu, Zoea Racovita, Florica Moldoveanu, Costin-Anton Boiangiu, Alin Moldoveanu, Gabriel Hera, “Neuron GIS solutions for the optimal path selection”, The 11th International Conference on Control System and Computer Science, position 11.10, Volume II, Bucharest, May 1997.

[19] Costin-Anton Boiangiu, Andrei-Cristian Spataru, Andrei-Iulian Dvornic, Ion Bucur “Merge techniques for large multiple-pass scanned images”, Proceedings of the 1st WSEAS International Conference on Visualization, Imaging and Simulation, Bucharest, Romania, November 2008, pp. 67-71.

[20] Costin-Anton Boiangiu, Dan-Cristian Cananau, Ion Bucur “Document layout analyze using hierarchical processing”, Proceedings of the 1st WSEAS International Conference on Visualization, Imaging and Simulation, Bucharest, Romania, November 2008, pp. 72-76.

[21] C. A. Boiangiu and A. I. Dvornic, “Modern preprocessing techniques for automatic content conversion systems”, *Annals of DAAAM for 2008 & Proceedings of the 19th International DAAAM Symposium*, Editor B. Katalinic, Published by DAAAM International (Vienna, Austria), Trnava, Slovakia, October 22-25, 2008, pp. 0123-0124.

[22] C. A. Boiangiu and D. C. Cananau, “Combined approaches in automatic page clustering for content conversion”, *Annals of DAAAM for 2008 & Proceedings of the 19th International DAAAM Symposium*, Editor B. Katalinic, Published by DAAAM International (Vienna, Austria), Trnava, Slovakia, October 22-25, 2008, pp. 0121-0122.

[23] Y. Zheng, H. Li and D. Doermann, “A model-based line Detection algorithm in documents”, Proceedings of the Seventh International Conference on Document Analysis and Recognition, Vol. 1, Edinburgh, Scotland, August 2003, pp. 44-48.

[24] F. Aurenhammer, “Voronoi diagrams - A survey of a fundamental geometric data structure”, *ACM Computing Survey*, Volume 23, Issue 3, September 1991, pp. 345-405.

[25] L. Likforman-Sulem and C. Faure, C., “Extracting text lines in handwritten documents by perceptual grouping”, *Advances in handwriting and drawing: a multidisciplinary approach*, Paris, 1994.