

بسم الله الرحمن الرحيم



جامعة السودان للعلوم والتكنولوجيا

كلية الدراسات العليا

\*\*\*

## عقدة بيانات السرطان بإستخدام خوارزمية الخطوتين

### Cancer patients Data Clustering Using Two-Steps Algorithm

بحث مقدم كأحد متطلبات نيل درجة الماجستير في علوم الحاسوب

المشرف:  
د.محمد الحافظ مصطفى

مقدم البحث:  
أحمد حمزة عثمان أحمد

سبتمبر 2008

الحمد لله

الحمد لله الذي أعانى على اتمام هذا البحث المتواضع ولما حصلت عليه من معرفة وأحمد الله تبارك وتعالى أن تقضي علي بأن زورني بما لم أكن اعرفه حتى تم إخراج هذا البحث الذي أهدف به بأن يُسهم في تطبيقات تقنيات التقسيم وذلك لايجاد نتائج يمكن ان تفيد المجتمع خاصة في مجتمعنا السوداني لأن هذا البحث أعتمد على البيئة السودانية في مدخلاته وبالتالي مخرجاته بلا شك كانت عائنة لنفس البيئة .

## الأية

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

((فَلَوْ كَانَ الْبَحْرُ مِدَادًا لِكَلْمَاتِ رَبِّي لَنَفِدَ الْبَحْرُ قَبْلَ أَنْ تَنْفَدَ كَلِمَاتُ رَبِّي وَلَوْ جِئْنَا بِمَثِيلِهِ مَذَدًا))

## صدق الله العظيم سورة الكهف – الآية (109)

## اداء

إلى من ربياني وعلماني دنيا الحياة والعلم والبحث عن الهدف  
(والذى ووالدى)

الى التي وقفت بجانبى ليل نهار وكان لها القدر المعلى فى إخراج هذا البحث(زوجتى)

الى كل العلماء الذين بذلوا جهودهم واروا حبهم للقدم والأزدهار

إلى كل من يبحث عن الجديد في دنيا التكنولوجيا

إلى كل والد ووالدة يطمحان بأن يصل ابنائهم الى أعلى درجات العلم

إلى أساتذتنا الاجلاء واخواننا الباحثين والطلاب .....

اليكم ولكم جميعاً أهدي هذا البحث المتواضع سائل المولى ان تعم به  
الفائدة

## شكر و عرفان

الشکر أجزله الله الواحد القهار. . .

ما طلعت شمس وما غاب نهار.....

الشکر أوفره لكل من نصب خيمة علم كمنار.....

الشکر أوسعه لكل والدٍ ووالدة رفعوا شعار العلم شعار.....

الشکر أكمله لكل معلم ومعلمة ينهضون بالجبال لإزالة ما على عقولهم من  
غبار.....

الشکر خالصه لجامعة إفريقيا العالمية التي قدمت وما زالت تقدم العلم لطلابها  
أنهاراً انهاراً.. وأخص منهم الدكتور قسم السيد ابراهيم والأستاذ المربى الدكتور  
عماد تاج الدين ابراهيم

والشکر أجزله لأستاذى الدكتور (محمد الحافظ مصطفى) الذى ظل خلفى ليل نهار  
ولم يدخل علي بعلم وأفكار.....

والشکر لكل أساتذتى الذين تلقيت على أيدهم العلم في جميع المراحل التعليمية  
والشکر كل الشکر للزماء والزميلات بجامعة السودان الذين كنت معهم طيلة فترة  
الدراسة وأخص بهم الصديق العزيز / البراء ابو عبيدة ..رفيق دراستي وعملاً  
والزميلاً ندى محمد عثمان والزميل رامى سعد الدين والزميل أبو بكر الصافى

كما أخص بالشكر ايضا الاخ الزميل الصديق/ عبد الماجد محمد والاخ عبد الرحمن ادريس والاستاذ النور عثمان الذين وقفوا معى فى إخراج هذا البحث  
ولا انسى ان اشكراً أسرة مستشفى الذرة وأخص منهم الاستاذه /ست النساء على  
ما أمدتني به من معلومات للأكمال هذا البحث

## المستخلص

علم التقسيب فى البيانات هو العلم الذى يبحث فى عملية الكشف عن معلومات ذات فائدة فى قواعد البيانات الكبيرة او أى بيانات كثيرة محفوظة بـأى شكل . و من أهم عمليات التقسيب طريقة تحليل العنقدة وهى طريقة تهدف الى تقسيم البيانات الى تجمعات من البيانات وايجاد معلومات لم تكن معروفة من قبل او لم يهتم بها الخبراء فى الحقل. والعنقدة هي تقسيم البيانات الى مجموعة من الاصناف اعتمادا على اشتراكها بالخواص المتشابهة . وتم تطبيق هذا البحث على بيانات مرضى السرطان حيث يعتبر المرض من الأمراض المنتشرة فى السودان ، اما عن هذه البيانات التى تم الحصول عليها فكانت بيانات جيدة ولكنها تحتوى على قيم مفقودة وبعض القيم الغير منطقية فعمل البحث على تنظيف هذه البيانات حتى يتم الحصول على نتائج منطقية ومفيدة و جديدة فكانت النتائج منطقية من حيث التقسيم الى مجموعات فكانت هنالك عدد من التجارب فى عملية التقسيم ، حيث تم التقسيم الى عشرة عناقيد وتسعة وثمانية الى ان حصلنا على مجموعتين ولكن هذه التقسيمات لم تظهر نتائج جديدة. وخرج البحث بعد من التوصيات يمكن ان تظهر معلومات جديدة فيما يلى إضافة هذه البيانات بزيادتها او استخدام خوارزمية عنقدة غير خوارزمية الخطوتين(Tow-Steps).

# **Abstract**

Data mining is a science that relates for knowledge and gives useful information for large database or any amount of data saved in any manner.

One of important techniques of data mining called by Clustering method, this method produce some of groups or clusters, some of them include anomalies cluster or anomalies group, this cluster unknown by experts or workers in the hospital .

They are many data mining algorithms such as (Tow-Step) that is used to data cluster in ALTHRAA hospital in Khartoum.

The data collected in 2007 by International Health care group. This data talked Microsoft Excel format, and included to some problem such as missing values and outlier values, but this problem solved by Data Cleansing stage.

Data mining implemented about (2-10) clusters or groups but not absorbed any new discover Knowledge and information.

The data set implemented in own project included to some homogenous values like the Age or Sex attributes also included some heterogenous values such as Morphology or topography attributes .

All of this tested will be let to new discover Knowledge or information in near future, but I thing if increased the data set.

Data mining is a new science in computer field that is development the counters and companies to success.

# فهرس الأشكال

رقم الصفحة	موضوع الشكل	رقم الشكل
12	المسافة بين عناصر العنقود الواحد وعناصر العناقيد المختلفة	الشكل (1.2)
13	العنقاد المفصولة كلها	الشكل (2.2)
13	أربعة عناقيد معتمدة على المركز	الشكل (3.2)
13	عناقيد متغيرة	الشكل (4.2)
15	اثنان من العناقيد المتلاحم	الشكل (5.2)
25	العنقود الاول عندما تم التقسيم إلى عنقودين	الشكل (1.4)
26	العنقود الثاني عندما تم التقسيم إلى عنقودين	الشكل (2.4)
27	العنقود الاول عندما تم التقسيم إلى ثلاثة عناقيد	شكل (3.4)
28	العنقود الثاني عندما تم التقسيم إلى ثلاثة عناقيد	شكل (4.4)
29	العنقود الثالث عندما تم التقسيم إلى ثلاثة عناقيد	شكل (5.4)
30	العنقود الاول عندما تم التقسيم إلى أربعة عناقيد	شكل (6.4)
31	العنقود الثاني عندما تم التقسيم إلى أربعة عناقيد	شكل (7.4)
32	العنقود الثالث عندما تم التقسيم إلى أربعة عناقيد	شكل (8.4)
33	العنقود الرابع عندما تم التقسيم إلى أربعة عناقيد	شكل (9.4)
34	العنقود الاول عندما تم التقسيم إلى خمسة عناقيد	شكل (10.4)
35	العنقود الثاني عندما تم التقسيم إلى خمسة عناقيد	شكل (11.4)
36	العنقود الثالث عندما تم التقسيم إلى خمسة عناقيد	شكل (12.4)
37	العنقود الرابع عندما تم التقسيم إلى خمسة عناقيد	شكل (13.4)
38	العنقود الخامس عندما تم التقسيم إلى خمسة عناقيد	شكل (14.4)
39	العنقود الاول عندما تم التقسيم إلى ستة عناقيد	شكل (15.4)
40	العنقود الثاني عندما تم التقسيم إلى ستة عناقيد	شكل (16.4)
41	العنقود الثالث عندما تم التقسيم إلى سبعة عناقيد	شكل (17.4)
42	العنقود الخامس عندما تم التقسيم إلى سبعة عناقيد	شكل (18.4)
43	العنقود السادس عندما تم التقسيم إلى ثمانية عناقيد	شكل (19.4)
44	العنقود السابع عندما تم التقسيم إلى ثمانية عناقيد	شكل (20.4)
45	العنقود الرابع عندما تم التقسيم إلى تسع عناقيد	شكل (21.4)
46	العنقود الخامس عندما تم التقسيم إلى تسع عناقيد	شكل (22.4)
47	العنقود الثاني عندما تم التقسيم إلى عشرة عناقيد	شكل (23.4)

# فهرس الجداول

رقم الصفحة

موضوع الجدول

رقم الجدول

24

وصف البيانات الخام (Data set Description)

جدول (1.4)

# فهرس المحتويات

الصفحة	الموضوع	الباب
2	المقدمة	الباب الأول
2	المقدمة	1.1
2	المقصود بالتنقیب في البيانات	2.1
2	تعريف مشكلة البحث	3.1
2	أهداف البحث	4.1
3	منهجية البحث	5.1
4	هيكلية البحث	6.1
5	التنقیب في البيانات	الباب الثاني
6	تعريف	1.2
6	العمليات الأساسية التي تعتبر ضمن عمليات أو مهام	2.2
6	التنقیب	
7	نماذج تطبيقية في تنقیب البيانات	3.2
8	تطبيقات التنقیب في البيانات	4.2
8	اوحة الفصور في تنقیب البيانات	5.2
8	الادوات والبرامج المستخدمة في تنقیب البيانات	6.2
8	<b>Clementine 7.0</b>	1.6.2
9	<b>Weka</b>	2.6.2
9	اختيار التقنية المناسبة	7.2
9	تخطيط عمليات التنقیب في البيانات	8.2
11	طرق تنقیب البيانات	9.2
11	قاعدة الارتباط	1.9.2
11	العنقدة	1.9.2
11	تعريف	1.2.9.2
11	وصف العنقدة	2.2.9.2
12	متطلبات العنقدة في تنقیب البيانات	3.2.9.2
14	خوارزميات العنقدة	4.2.9.2
15	<b>Tow-Step</b>	5.2.9.2
15	كيفية عمل الخوارزمية رياضيا في قياس المسافة لإجراء	6.2.9.2
15	التصنيف	3.9.2
17	بناء النموذج وتجهيز البيانات	الباب الثالث
18	مقدمة	1.3
19	تحرى واستكشاف البيانات	2.3
19	تجهيز البيانات	3.3
20	نموذج التنقیب في البيانات	4.3

20	تقييم وتفسير النتائج	5.3
20	تعيم النتائج	6.3
21	دراسة الحالة والنتائج	الباب الرابع
22	مقدمة	1.4
22	جمع البيانات	2.4
22	تجهيز البيانات التي جمعت	3.4
23	أنواع البيانات	1.3.4
23	مشاكل البيانات	2.3.4
25	نتائج العنفدة في تنقيب بيانات مرض السرطان	4.4
25	الشكل التفصيلي	1.4.4
47	إستخراج البيانات بشكل وصف عام للجموعات	2.4.4
51	تقييم ومناقشة النتائج	5.4
52	الوصيات والختمة	الباب الخامس
53		الوصيات
54		والختمة
55	.....	المراجع