



**UNIVERSIDADE FEDERAL RURAL DO SEMI-ÁRIDO  
UNIVERSIDADE DO ESTADO DO RIO GRANDE DO NORTE  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA  
COMPUTAÇÃO**



**ADRIANA MARA GUIMARÃES DE FARIAS**

**DEFINIÇÃO DE ESTRATÉGIAS DE COMBATE E PREVENÇÃO A CRIMES POR  
MEIO DO USO DE ALGORITMOS DE AGRUPAMENTO E ANÁLISE DE  
CONCEITOS FORMAIS**

**MOSSORÓ**

**2014**

**ADRIANA MARA GUIMARÃES DE FARIAS**

**DEFINIÇÃO DE ESTRATÉGIAS DE COMBATE E PREVENÇÃO A CRIMES POR  
MEIO DO USO DE ALGORITMOS DE AGRUPAMENTO E ANÁLISE DE  
CONCEITOS FORMAIS**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação – associação ampla entre a Universidade do Estado do Rio Grande do Norte e a Universidade Federal Rural do Semi-Árido, para a obtenção do título de Mestre em Ciência da Computação.

Orientador: Prof<sup>a</sup>. Dra. Angélica Félix de Castro – UFERSA  
Co-Orientador: Prof. Dr. Marcos Evandro Cintra – UFERSA.

**MOSSORÓ**

**2014**

**Catálogo da Publicação na Fonte.  
Universidade do Estado do Rio Grande do Norte.**

Farias, Adriana Mara Guimarães de.

Definição de estratégias de combate e prevenção a crimes por meio do uso de algoritmos de agrupamento e análise de conceitos formais. / Adriana Mara Guimarães de Farias. – Mossoró, RN, 2014

78 f.

Orientador(a): Prof.<sup>a</sup> Angélica Félix Castro.

Dissertação (Mestrado em Ciência da Computação). Universidade do Estado do Rio Grande do Norte. Universidade Federal Rural do Semi-Árido. Programa de Pós-Graduação em Ciência da Computação.

1. Algoritmos de agrupamento - Dissertação. 2. *Hot spots* criminais - Dissertação. 3. Análise de conceitos formais - Dissertação. I. Castro, Angélica Félix. II. Universidade do Estado do Rio Grande do Norte. III. Título.

UERN/BC

CDD 005.1

**ADRIANA MARA GUIMARÃES DE FARIAS**

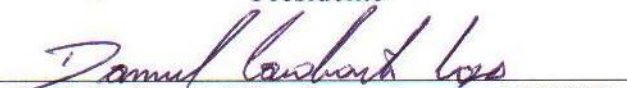
**DEFINIÇÃO DE ESTRATÉGIAS DE COMBATE E PREVENÇÃO A CRIMES POR  
MEIO DO USO DE ALGORITMOS DE AGRUPAMENTO E ANÁLISE DE  
CONCEITOS FORMAIS**


Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação para a obtenção do título de Mestre em Ciência da Computação.

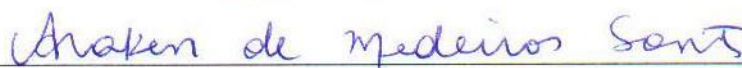
APROVADA EM: \_\_\_ / \_\_\_ / \_\_\_\_\_

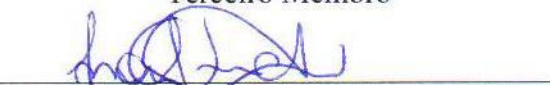
**BANCA EXAMINADORA**

  
\_\_\_\_\_  
Profa. Dra. Angélica Félix de Castro – UFRSA  
Presidente

  
\_\_\_\_\_  
Prof. Dr. Daniel Cavalcante Lopes – UFRSA  
Primeiro Membro

  
\_\_\_\_\_  
Prof. Dr. Marcos Evandro Cintra – UFRSA  
Segundo Membro

  
\_\_\_\_\_  
Prof. Dr. Araken de Medeiros Santos – UFRSA  
Terceiro Membro

  
\_\_\_\_\_  
Profa. Dra. Ana Trindade Winck – UFSM  
Membro Externo

## **AGRADECIMENTOS**

Os agradecimentos principais vão para os meus orientadores, Angélica Félix de Castro, Dannel Cavalcante Lopes e Marcos Evandro Cintra, com muito esforço e dedicação me ajudaram a produzir esse trabalho.

Agradeço a pessoa do Major Carlos Macêdo pelo apoio a esse trabalho fornecendo os dados do CIOSP e por sempre acreditar que bons resultados poderiam ser obtidos.

Agradeço aos meus parceiros e colaboradores, Francisco Paulo e Fernando Gomes, pelas dicas, sugestões e críticas que ajudaram esse trabalho se desenvolver a cada dia.

Agradeço o apoio e preocupação dos meus pais, Antonia e Vilmar, a cada dia sempre perguntando se eu não estava cansada de estudar tanto.

Agradeço o apoio do meu esposo, Felipe Moraes, por me ajudar na hora certa e não me deixar perder o foco.

Por fim, agradeço a CAPES, pelo financiamento deste trabalho.

## RESUMO

Pesquisas em segurança pública são temas em crescimento. Neste sentido, os algoritmos de aprendizado de máquina têm sido utilizados para extrair conhecimento a partir de bases de dados criminais. Tais bases têm como principal objetivo apenas manter os registros de ocorrências e gerar estatísticas. A extração automática de conhecimento, a partir de tais bases de dados, permite a melhoria e o planejamento de estratégias para prevenir e combater a criminalidade. Assim, neste trabalho, dois modelos são apresentados com base em algoritmo de agrupamento e análise de conceitos formais. Os modelos foram gerados utilizando dados reais para o período de dezembro de 2011 a junho de 2013, da cidade de Mossoró - RN. Os algoritmos de agrupamento foram utilizados para obter pontos quentes criminais, ou seja, locais de alta incidência de crimes. A análise da teoria de conceitos formais foi utilizada para a extração de modelos visuais que descreve os padrões que caracterizam as atividades criminais na forma de reticulados conceituais. Os reticulados conceituais fornecem modelos gráficos que também podem ser utilizados na definição de estratégias para combater e prevenir o crime. Os modelos foram avaliados por especialistas em segurança pública que deram *feedback* positivo e aprovaram o uso dos modelos.

**Palavras-chaves:** Algoritmos de agrupamento. *Hot spots* criminais. Análise de conceitos formais. Segurança pública.

## ABSTRACT

Public safety research is a growing research topic. In this sense, machine learning algorithms have been used to extract knowledge from criminal databases whose primary goal has always been to just maintain records and generate statistics. The automatic extraction of knowledge from such databases, allows the improvement and planning strategies to prevent and combat crimes. Accordingly, in this work, two models are presented based on collation and analysis of formal concepts algorithm. The models were generated using actual data for the period December, 2011 to June, 2013 from the city of Mossoró-RN. Clustering algorithms were used to obtain criminal hot spots, *i.e.*, places of high crime incidence. The analysis of the theory of formal concepts was used for extracting visual models describing patterns that characterize criminal activities in the form of concept lattices. The concept lattices provide graphical models that can also be used for defining strategies to combat and prevent crime. The models were evaluated by public safety experts who gave positive feedback and approved the usage of the models.

**Palavras-chaves:** Clustering algorithms. Criminal hot spots. Formal concept analysis. Public safety.

## LISTA DE FIGURAS

Figura 1 – Sistema Nacional de Coleta e Análise de Dados Criminais .....	18
Figura 2 – Mapa de <i>hot spot</i> criminal de homicídios na cidade de Washington .....	21
Figura 3 – Reticulado conceitual .....	29
Figura 4 – Definição do atributo "DATA" em termos de valores binários .....	38
Figura 5 – Definição do atributo "HORÁRIO" em termos de valores binários .....	38
Figura 6 – Definição do atributo "TYP-ENG" em termos de valores binários .....	39
Figura 7 – <i>Hot Spots</i> criminais obtidos com o algoritmo k-Means.....	46
Figura 8 – <i>Hot Spots</i> criminais obtidos no período da madrugada.....	47
Figura 9 – Distribuição dos <i>hot spots</i> criminais obtidos no período da madrugada...48	
Figura 10 – <i>Hot Spots</i> criminais obtidos no período da manhã .....	48
Figura 11 – Distribuição de <i>Hot Spots</i> criminais no período da manhã.....	49
Figura 12 – <i>Hot Spots</i> criminais obtidos no período da tarde.....	50
Figura 13 – Distribuição de <i>Hot Spots</i> criminais no período da tarde.....	51
Figura 14 – <i>Hot Spots</i> criminais obtidos no período da noite .....	51
Figura 15 – Distribuição de <i>Hot Spots</i> criminais no período da noite .....	52
Figura 16 – Distribuição dos <i>Hot Spots</i> criminais no mês de junho de 2012.....	54
Figura 17 – Distribuição dos <i>Hot Spots</i> criminais em junho de 2012 .....	55
Figura 18 – Distribuição dos <i>Hot Spots</i> criminais no mês de Dezembro de 2012 .....	55
Figura 19 – Distribuição dos <i>Hot Spots</i> criminais em Dezembro de 2012.....	56
Figura 20 – Reticulado Conceitual de Crime por Período .....	57
Figura 21 – Reticulado Conceitual de Homicídios no Alto de São Manoel.....	58
Figura 22 – Reticulado Conceitual com todos os Crimes no período da Madrugada no bairro Alto de São Manoel.....	59
Figura 23 – Mapa com 8 <i>hot spots</i> criminais.....	67
Figura 24 – Mapa com 9 <i>hot spots</i> criminais.....	68
Figura 25 – Mapa com 10 <i>hot spots</i> criminais.....	69
Figura 26 – Mapa com 11 <i>hot spots</i> criminais.....	70
Figura 27 – Mapa com 13 <i>hot spots</i> criminais.....	71
Figura 28 – Mapa com 14 <i>hot spots</i> criminais.....	72
Figura 29 – Mapa com 15 <i>hot spots</i> criminais.....	73
Figura 30 – Mapa com 16 <i>hot spots</i> criminais.....	74
Figura 31 – Mapa com 17 <i>hot spots</i> criminais.....	75



Figura 32 – Mapa com 18 <i>hot spots</i> criminais.....	76
Figura 33 – Mapa com 19 <i>hot spots</i> criminais.....	77
Figura 34 – Mapa com 20 <i>hot spots</i> criminais.....	78

## LISTA DE TABELAS

Tabela 1 – Gastos em Segurança Pública pelo Governo Federal do Brasil.....	11
Tabela 2 – Tabela atributo x valor com dados para agrupamento .....	22
Tabela 3 – Tabela atributo x valor - exemplo do brinquedo .....	28
Tabela 4 – Contexto Formal baseado na Tabela 3 .....	28
Tabela 5 – Tabela de registros de ocorrências .....	36
Tabela 6 – Descrição dos atributos dos registros de ocorrências do Centro Integrado de Operações em Segurança Pública.....	36
Tabela 7 – Tabela de registros de ocorrências pré-processada.....	40
Tabela 8 – Cálculo do fator de periculosidade .....	44
Tabela 9 – Registros de Ocorrências Mensais no ano de 2012.....	53
Tabela 10 – Ranking de Periculosidade.....	60

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	11
<b>2 ANÁLISE CRIMINAL E <i>HOT SPOTS</i> CRIMINAIS</b> .....	14
2.1 ANÁLISE CRIMINAL .....	14
2.1.1 Tipificação da análise criminal.....	15
2.1.2 Avaliação das bases criminais.....	16
2.2 <i>HOT SPOT</i> CRIMINAL.....	18
2.2.1 Características dos <i>Hot Spots</i> criminais.....	19
2.2.2 Critérios de obtenção dos <i>Hot Spots</i> criminais.....	19
2.2.3 Mapa de <i>Hot Spots</i> criminais .....	20
<b>3 ALGORITMOS DE AGRUPAMENTO E ANÁLISE DE CONCEITOS FORMAIS</b> ..	22
3.1 ALGORITMOS DE AGRUPAMENTO.....	22
3.1.1 Medidas de similaridade.....	23
3.1.2 Critérios de agrupamento .....	25
3.1.3 Etapas da análise de agrupamento.....	25
3.2 ALGORITMO <i>K-MEANS</i> .....	26
3.3 ANÁLISE DE CONCEITOS FORMAIS.....	26
3.3.1 Definições .....	26
3.3.2 Padronização de atributos para extração de conceitos formais.....	27
3.3.3 Reticulados conceituais .....	29
<b>4 REVISÃO BIBLIOGRÁFICA</b> .....	30
4.1 TRABALHOS RELACIONADOS À ANÁLISE DA CRIMINALIDADE .....	30
4.2 TRABALHOS RELACIONADOS A DEFINIÇÃO DE <i>HOT SPOTS</i> CRIMINAIS COM USO DE ALGORITMOS DE AGRUPAMENTO .....	31
4.3 TRABALHOS RELACIONADOS AO ESTUDO DE MODELOS BASEADOS NA ANÁLISE DE CONCEITOS FORMAIS.....	33
<b>5 METODOLOGIA PARA OBTENÇÃO DOS MODELOS DE APOIO À PREVENÇÃO E COMBATE A CRIMES</b> .....	35
5.1 REVISÃO BIBLIOGRÁFICA.....	35
5.2 OBTENÇÃO DE DADOS REAIS.....	35
5.3 PRÉ-PROCESSAMENTO DOS DADOS.....	37
5.4 OBTENÇÃO DE <i>HOT SPOTS</i> CRIMINAIS COM UTILIZAÇÃO DO ALGORITMO <i>K-MEANS</i> .....	40

5.5 OBTENÇÃO DOS RETICULADOS CONCEITUAIS COM UTILIZAÇÃO DE ANÁLISE DE CONCEITOS FORMAIS.....	42
5.6 DEFINIÇÃO DA CLASSIFICAÇÃO DE PERICULOSIDADE DOS BAIRROS DE MOSSORÓ A PARTIR DA COMBINAÇÃO DOS <i>HOT SPOTS</i> CRIMINAIS E RETICULADOS CONCEITUAIS .....	43
5.7 AVALIAÇÃO E VALIDAÇÃO DOS MODELOS OBTIDOS.....	45
<b>6 RESULTADOS</b> .....	46
6.1 <i>HOT SPOTS</i> CRIMINAIS .....	46
6.2 RETICULADOS CONCEITUAIS .....	56
6.3 RANKING DE PERICULOSIDADE .....	59
6.4 ANÁLISE DOS MODELOS POR ESPECIALISTAS .....	61
<b>7 CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS</b> .....	62
7.1 DIVULGAÇÃO DE RESULTADOS.....	62
7.2 TRABALHOS FUTUROS .....	63
<b>REFERÊNCIAS</b> .....	64
<b>ANEXO A – Mapas com <i>Hot spots</i> criminais para todos os períodos, de 8 a 20 centros</b> .....	67

## 1 INTRODUÇÃO

A criminalidade é um tema recorrente nos veículos de comunicação, tais como, rádio, telejornais e internet. Esse tema possui grande relevância devido o aumento da criminalidade que gera inúmeros prejuízos econômicos, afetando o bem estar da população. No entanto, o governo brasileiro tem investido pesadamente em segurança pública, como pode ser visto na Tabela 1 os enormes gastos nas áreas de policiamento, defesa civil e inteligência da polícia.

Tabela 1 – Gastos em Segurança Pública pelo Governo Federal do Brasil.

Ano	Policiamento	Defesa Civil	Informação e Inteligência	Total
2010	13.199.609.490,90	2.955.228.589,68	452.265.850,42	16.607.184.931,00
2011	18.591.783.723,58	1.630.080.129,49	448.806.582,24	20.670.670.435,31
2012	17.557.948.076,05	2.569.170.681,84	880.055.365,26	21.007.174.123,15

Fonte: (FÓRUM BRASILEIRO DE SEGURANÇA PÚBLICA, 2013).

Como pode ser visto na Tabela 1, os maiores gastos foram com policiamento, correspondendo a mais de 18 bilhões em 2011 e mais de 17 bilhões em 2012, enquanto que os gastos em informação e inteligência foram mais de 448 milhões em 2011 e mais de 880 milhões em 2012. Para a realização das atividades de policiamento é necessário investir em viaturas, câmeras de vigilância, armas e uniformes, além da manutenção do recurso humano, ou seja, os policiais. Por isso os gastos são mais elevados. Contudo, se fosse feito mais investimentos em informação e inteligência, a distribuição desses recursos seria mais eficiente. Diante desse cenário, esse trabalho focou na proposta de fundamentar modelos de apoio ao planejamento estratégico de medidas de prevenção e combate à criminalidade. Note que todo esse investimento em segurança pública, o Brasil ficou na 18ª posição no *ranking* mundial dos países com maior índice de homicídios (FÓRUM BRASILEIRO DE SEGURANÇA PÚBLICA, 2013).

Porém, foram realizadas iniciativas buscando diminuir esses índices, entre elas pode-se destacar a campanha do desarmamento instituída a partir de junho de 2004. Essa campanha teve como objetivo recolher o maior número possível de armas não registradas em posse da população visando diminuir o índice de

homicídios por arma de fogo (MESA DA CÂMARA DOS DEPUTADOS, 2013). O controle de armas por meio da campanha pode ser entendido como uma estratégia de prevenção contra o crime de homicídio. A definição desse tipo de estratégia pode ser auxiliada por informações e modelos obtidos a partir das bases criminais numa tentativa de focar o planejamento de acordo com as características que compreendem o fenômeno criminal. Com isso, o âmbito criminal pode abranger maior número de crimes, além dos homicídios, como no caso da campanha de desarmamento. Por isso, nesse trabalho foram incluídos os crimes de furto, roubo, homicídio e tráfico de drogas.

O presente trabalho teve como objetivo utilizar algoritmo de agrupamento e análise de conceitos formais a fim de processar dados criminais, permitindo a extração de padrões dos crimes e a identificação dos locais de maior concentração criminal. Por meio da utilização de algoritmo de agrupamento é possível obter grupos de objetos com características semelhantes. Logo, neste trabalho, a utilização de algoritmo de agrupamento buscou encontrar locais de maior concentração criminal, definidos como *hot spots* criminais. Com a utilização de análise de conceitos formais é possível extrair padrões de um conjunto de objetos baseados em suas características, assim, neste trabalho, foram obtidos padrões criminais por meio da análise dos registros de ocorrências. Os dados criminais aplicados neste trabalho foram obtidos a partir dos registros de ocorrência da cidade de Mossoró-RN e por meio dos resultados foi elaborada uma estratégia que classifica cada bairro da cidade de acordo com seu nível de periculosidade, obtendo assim um *ranking* dos bairros. A obtenção desses resultados permitiu auxiliar na definição estratégica de prevenção e combate à criminalidade.

A obtenção desses resultados foi possível mediante a utilização de dados reais da base de registros de ocorrências do Centro Integrado de Operações Policiais, CIOSP, da cidade de Mossoró-RN. A base fornecida continha 43.390 registros de ocorrências obtidos durante o período de dezembro/2011 a junho/2013. Os dados mais relevantes para o trabalho foram coordenadas geográficas, tipo e horário do crime e bairro.

Observa-se na Tabela 1 que muito se tem gasto em policiamento numa tentativa de diminuir os índices de criminalidade. Porém, para diminuir esses índices é necessário conhecer seus padrões, saber como estão se manifestando e em quais locais. Com uma análise dos dados criminais por meio da aplicação de técnicas

computacionais é possível obter tais resultados. A partir disso, pode-se traçar estratégias de prevenção e combate à criminalidade, redistribuindo os recursos disponíveis de forma mais eficiente. Conseqüentemente, diminuiria os índices criminais e os gastos. Por isso, o foco deste trabalho foi utilizar técnicas de inteligência artificial capazes de fornecer tais informações que modelos estatísticos não são capazes de alcançar seguindo um modelo possível de ser padronizado em qualquer instituição de segurança pública.

Os resultados obtidos foram analisados por especialistas da área, policiais do CIOSP, e receberam *feedback* positivo, neste caso, considera-se o fato de que os resultados demonstram o cenário da criminalidade na cidade de Mossoró com precisão adequada, além disso, foram feitas algumas sugestões de forma a enriquecer mais ainda o trabalho.

O restante desse trabalho está organizado da seguinte forma: o Capítulo 2 apresenta os fundamentos teóricos sobre análise criminal e *hot spots* criminais. No Capítulo 3 são apresentados os conceitos sobre algoritmos de agrupamentos e análise de conceitos formais. No Capítulo 4 são apresentados os trabalhos relacionados com descrição das técnicas utilizadas e resultados obtidos. No Capítulo 5 é apresentada a metodologia adotada neste trabalho. No Capítulo 6 são apresentados os resultados obtidos com este trabalho. Por fim, no Capítulo 7 são expostas as conclusões, publicações e os trabalhos futuros.

## 2 ANÁLISE CRIMINAL E *HOT SPOTS* CRIMINAIS

Esse capítulo descreve os conceitos básicos sobre a tarefa de análise criminal, assim como o conceito de *hot spots* criminais, extração e análise.

### 2.1 ANÁLISE CRIMINAL

A análise criminal pode ser definida da seguinte forma (PEIXOTO, 2008):

Constitui-se no uso de uma coleção de métodos para planejar ações e políticas de segurança pública, obter dados, organizá-los, analisá-los, interpretá-los e deles tirar conclusões.

Por meio de métodos estatísticos é possível realizar o processamento dos dados e obter informações capazes de ajudar a conhecer as causas da criminalidade.

Através da análise criminal é possível obter modelos de padrões de crimes e avaliar suas tendências (GAY; BEALL; BOWERS, 1982). Esse processo fornece apoio às áreas operacional e administrativa da polícia durante o planejamento e distribuição dos recursos disponíveis com o objetivo de prevenir e suprimir ações criminosas.

Na tentativa de descrever padrões do crime deve ser observada pelo menos uma característica de um conjunto de ocorrências que se repete ao longo do tempo. Essa característica pode ser, por exemplo, o local, o dia, a hora, o perfil da vítima ou do autor do delito.

A análise das tendências criminais permite a avaliação de uma espécie de prospecção, ou seja, é possível saber se um tipo de crime está aumentando, ou estabilizando, ou diminuindo em um determinado local.

Identificar e estruturar corretamente o problema é o primeiro passo para se obter bons resultado com uma análise criminal (PEIXOTO, 2008). Porém, para criar essa estrutura é necessário conhecer os fatores que condicionam o controle da criminalidade. Entre eles, pode-se listar:

- Densidade populacional e grau de urbanização.
- Variação na composição do contingente populacional local quanto a prevalência de jovens e indivíduos do sexo masculino.



- Presença de população transitória ou de não residentes.
- Meios de transporte disponíveis e sistema viário local.
- Aspectos culturais, educacionais, religiosos e oportunidades de lazer e entretenimento.
- Efetividade das instituições policiais locais.
- Políticas, métodos e processos de funcionamento das outras instituições do sistema de defesa social.
- Atitudes da cidadania em relação ao crime.

Todos esses fatores devem ser levados em consideração durante o processo de análise criminal, assim como os dados coletados nos registros de ocorrências que fornecem o arcabouço necessário para planejamento tático e operacional da polícia.

### **2.1.1 Tipificação da análise criminal**

Os resultados obtidos a partir da análise criminal servirão como informações para planejamentos diferentes. Diante disso, o processo de análise criminal pode ser tipificado como (GAY; BEALL; BOWERS, 1982).

- Análise Criminal Tática - produz informações que auxiliem o trabalho ostensivo e investigativo visando focar o policiamento em possíveis locais e horários. O objetivo principal da Análise Criminal Tática é identificar tendências e padrões da criminalidade.
- Análise Criminal Estratégica - está voltada para projeções de cenários, ou seja, resolução de problemas em longo período de tempo. Por meio dela é possível obter relatórios com dados estatísticos que permitem a elaboração de planos para aquisição de recursos futuros para a gestão.
- Análise Criminal Administrativa - inclui a produção de vários tipos de informações, desde os relacionados com os registros de ocorrências até os aspectos econômicos, sociais, geográficos e organizacionais.

### 2.1.2 Avaliação das bases criminais

Obter informações a partir dos registros de ocorrências é de muita importância para o processo da análise criminal.

Com a evolução das tecnologias, esse trabalho tem se tornado cada vez mais automatizado com ganho de inúmeras técnicas computacionais capazes de ampliar a qualidade e a quantidade de informações necessárias para o combate a criminalidade (COSTA, 2012).

A utilização de técnicas computacionais é, na verdade, uma necessidade (CRIMINALISTA, 2012):

Na Polícia Federal, por exemplo, a cada ano, mais de 6.000 discos rígidos e computadores são apreendidos em investigações policiais. O volume de dados contidos nos materiais seria da ordem de 720 terabytes, correspondendo, aproximadamente, a 36 vezes o tamanho da maior biblioteca do mundo.

Logo, a partir dessa informação pode-se ter uma noção da quantidade de dados que precisam ser processados diariamente. Se para cada registro de ocorrência existe uma série de características que configuram um crime, a análise de todos esses registros é um processo difícil e oneroso.

Porém, com aplicação de técnicas computacionais, a análise dessas características pode revelar a existência de padrões nas ocorrências criminais, ou seja, pode-se chegar a conclusão que está acontecendo mais furtos a mulheres jovens em determinado bairro ou que está acontecendo mais homicídios a homens com mais de quarenta anos utilizando arma branca, por exemplo.

As bases criminais armazenam as informações básicas que configuram um registro de ocorrência, listadas a seguir:

- Crime praticado.
- Local do crime.
- Horário do crime.

Além destas, inúmeras outras informações podem ser coletadas:

- Quantidade de envolvidos nos crimes.
- Localidade dos envolvidos.
- Motivação do crime.

- Idade da vítima e do criminoso.
- Sexo da vítima e do criminoso.
- Tipo do local onde o crime ocorreu.

Uma das maiores dificuldades relacionada a análise criminal é a falta de padronização das bases criminais, ou seja, de diferentes instituições de segurança pública, civil, militar e bombeiros, pois cada base possui uma estrutura diferente para armazenar suas informações. Segundo Costa (2012):

Configura-se a necessidade de desenvolver uma metodologia, sustentada por uma base teórica sólida e materializada em um ferramental especializado, associado a procedimentos apropriados, para que a polícia judiciária brasileira possa fazer frente aos desafios promovidos pela criminalidade moderna.

Com a falta de padronização nas bases de dados no Brasil e o volume de dados crescendo exponencialmente, o trabalho de análise criminal fica comprometido além de dificultar a geração de informações que retratem o cenário da criminalidade.

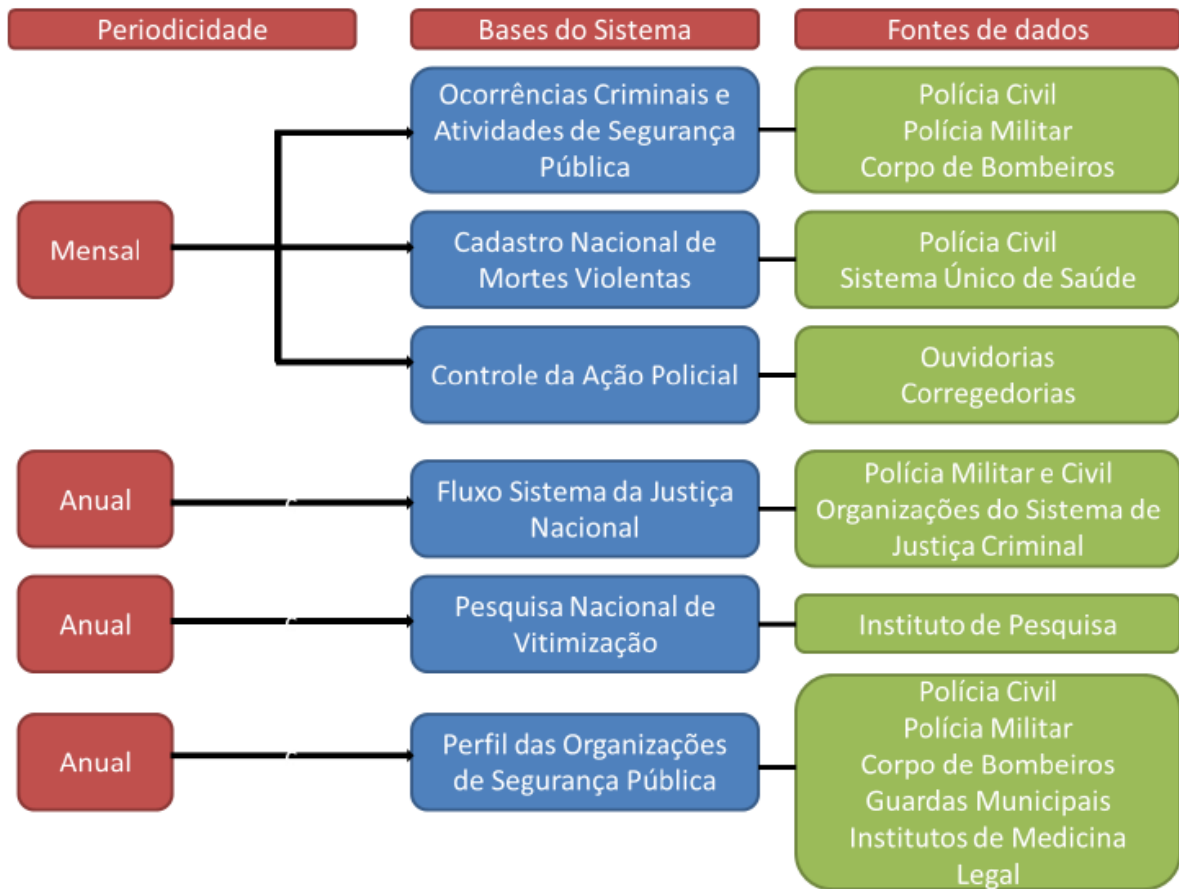
A partir de 2001, é importante notar que no Brasil, foi implantando um sistema nacional de coleta e análise de dados estatísticos sobre segurança pública (CRIMINALÍSTICA, 2012). O objetivo deste sistema é de reunir informações sobre ocorrências criminais e atividades policiais buscando traçar um perfil das organizações policiais brasileiras com foco em suas características, formação de efetivos, grau de modernização, entre outros.

Apesar dessa iniciativa, o sistema possui um padrão que ainda não foi adotado por todas as instituições que trabalham com bases criminais. A Figura 1 apresenta a estrutura do Sistema Nacional de Coleta e Análise de Dados Criminais.

A Figura 1 mostra informações com relação à periodicidade de coleta dos dados (mensal ou anual), os nomes das seis bases nacionais inseridas no sistema (veja coluna central), além das fontes que geram tais dados e alimentam as bases do sistema (terceira coluna), incluindo diversas instituições do governo federal, estadual e municipal.

De fato, cada uma dessas fontes de dados possui um padrão próprio, dificultando o trabalho da análise criminal como um todo.

Figura 1 – Sistema Nacional de Coleta e Análise de Dados Criminais.



Fonte: Criminalística (2012)

O problema em questão é padronizar a coleta dos dados, ou seja, definir um modelo de registro de ocorrências de forma que todos os dados sigam um padrão único.

## 2.2 HOT SPOT CRIMINAL

*Hot spot* criminal é uma área geográfica com alta concentração de incidentes criminais, ou seja, uma área em que o número de eventos criminosos é maior do que em qualquer outro lugar. Trata-se de um local onde as pessoas têm um maior risco de serem vitimadas.

Um lugar de interesse mais que o habitual. Uma área de instabilidade política, militar ou civil, geralmente considerada perigosa. Um lugar onde há muito perigo ou luta (BARROS, 2005).

No cotidiano, as pessoas tendem a reconhecer tais locais e introduzem em suas rotinas diárias o costume de evitar alguns lugares devido a essas manifestações criminosas (ECK et al., 2005).

### **2.2.1 Características dos *Hot Spots* criminais**

Os locais com maior concentração criminal são determinados pelas seguintes características (ZHANG et al., 2010):

- Quantidade de eventos no local.
- Informação espacial do local.
- Tempo do evento.
- Evento ocorrido.

A análise dessas características pode ajudar a polícia a identificar áreas de alta criminalidade e os tipos de crimes que estão sendo praticados. A análise de *hot spot* criminal pode responder muitos questionamentos devido ao número de características que estão ligadas a prática de crimes.

A detecção de um *hot spot* criminal não se limita apenas ao local, ela também inclui informações sobre como as ações criminosas se manifestam. Com a análise de *hot spot* criminal é possível responder dúvidas simples relacionadas aos diferentes tipos de crime (ZHANG et al., 2010). Por exemplo, considere as seguintes perguntas:

- Onde estão as drogas vendidas na cidade?
- Onde e quais pessoas compram essas drogas?

Na primeira pergunta, é preciso localizar os pontos de comercialização da droga. Encontrando esses pontos, é possível averiguar o perfil dos compradores e identificar onde estes residem, respondendo a segunda pergunta.

### **2.2.2 Critérios de obtenção dos *Hot Spot* criminais**

Ao analisar os índices de criminalidade deve-se levar em consideração os tipos de crimes registrados. Segundo Miranda et al. (2008) os crimes de furto, roubo

e homicídios tem suas origens, em grande parte, devido a manifestação do tráfico de drogas. Peixoto (2008) afirma que o índice de criminalidade de uma região é calculado com base no número de homicídios registrados seguido pelos números de furtos e roubos. Logo, existem tipos criminais que possuem maior fator de risco ou periculosidade que outros. Por exemplo, uma ocorrência de furto pode ser considerada menos perigosa que uma ocorrência de homicídio, isso por que o homicídio é um crime de atentado a vida de uma pessoa, enquanto que o furto é enquadrado como crime material.

O crime de furto pode ser definido como (MORAES; CAPOBIAANCO, 2011):

Crime de furto é toda conduta que consiste em subtrair ou assenhorar-se, para si ou para outrem, de coisa alheia móvel, em outras palavras, daquilo que não lhe pertence. É importante destacar que este ilícito só atinge bens móveis, ou seja, que podem ser deslocados de um lugar para outro, adotando-se, neste caso, o sentido real do termo e não o seu significado jurídico.

O crime de homicídio, por sua vez, pode ser definido como (MORAES; CAPOBIAANCO, 2011):

Crime de homicídio é matar alguém, é a violenta ocisão de um homem injustamente praticada por outro.

Logo, um crime de homicídio pode ser considerado com o fator de risco maior que um crime de furto, por envolver a vida de uma pessoa.


Assim, a análise de dados criminais deve considerar que existem crimes mais perigosos que outros para determinar o índice de periculosidade de um local.

### **2.2.3 Mapa de *Hot Spots* criminais**

A abordagem mais comum para a exibição de *hot spots* criminais é o mapa de pontos (ECK et al., 2005). O mapa de pontos quentes é popularmente conhecido mapa de pinos que representa o crime em um mapa na parede. Em uma ferramenta computacional, estes pontos quentes podem receber maiores informações, tal como o código que descreve o tipo, data e hora do crime.

A Figura 2 mostra o mapa de *hot spots* criminais para a cidade de Washington, nos Estados Unidos.

Figura 2 – Mapa de *hot spot* criminal de homicídios na cidade de Washington.



Fonte: (MALTZ; GORDON; FRIEDMAN, 2007).

A Figura 2 exibe o mapa da cidade de Washington com a marcação dos locais onde ocorreram crimes de homicídios no período de novembro de 2004 a novembro de 2006. É possível visualizar que os crimes ocorridos foram tipificados de acordo com o objeto utilizado, ou seja, arma, faca e outros.

Com o exemplo da Figura 2 pode-se ter uma noção da vantagem de obter *hot spots* criminais e plotá-los em um mapa. Isso porque o ganho de informação em se poder visualizar todos os registros de forma visual, saber onde eles estão se concentrando, poder diferenciá-los é de muito valor durante um planejamento estratégico, quando se tenta otimizar o uso dos recursos disponíveis.

O próximo capítulo trata de algoritmos de agrupamento e da teoria de análise de conceitos formais.

### 3 ALGORITMOS DE AGRUPAMENTO E ANÁLISE DE CONCEITOS FORMAIS

Nesse capítulo, são apresentadas as definições básicas sobre algoritmos de agrupamento e análise de conceitos formais.

#### 2.1 ALGORITMOS DE AGRUPAMENTO

Os métodos de agrupamento procuram organizar os objetos em grupos homogêneos se valendo do conceito de similaridade. A análise de agrupamento também é conhecida como análise de *cluster* ou *clusterização*. Trata-se de um conjunto de técnicas ou procedimentos capazes de classificar objetos a partir da observação das semelhanças e diferenças entre eles. O resultado desses procedimentos é o conjunto de grupos relativamente homogêneos que reúnem objetos similares entre si.

A aplicação dessa técnica ganhou mais popularidade quando passou a ser utilizada em mineração de dados (TURBAN et al., 2008). No âmbito da mineração de dados, a análise de agrupamento tem sido muito usada na detecção de fraudes e segmentação de mercado, por exemplo.

Seja um objeto  $O$ , descrito por  $P$  atributos ou características da forma  $O_i = \{A_1, A_2, \dots, A_p\}$ . Os dados fornecidos para obtenção desses grupos são colocados em uma matriz composta de  $N$  linhas e  $P$  colunas ( $N \times P$ ), também conhecida como *tabela x valor*, em que  $N$  representa os objetos e  $P$  representa as características que constituem cada objeto (FREI, 2006). A Tabela 2 apresenta um exemplo de *tabela x valor*.

Tabela 2 – Tabela atributo x valor com dados para agrupamento

	<b>Latitude</b>	<b>Longitude</b>	<b>Tipo criminal</b>
$Obj_1$	-5,175832	-37,353344	Furto
$Obj_1$	-5,200621	-37,363	Furto
$Obj_1$	-5,187903	-37,340645	Tráfico
⋮	⋮	⋮	⋮
$Obj_1$	-5,209902	-37,338885	Roubo

Fonte: autoria própria.



Na Tabela 2 são representados os registros de ocorrência em que cada registro compreende um objeto e cada objeto possui como atributos, latitude, longitude e tipo criminal.

### 3.1.1 Medidas de similaridade

Definir quais características constituem os objetos de maneira que estes possam ser considerados distintos uns dos outros é um dos passos mais importantes. A determinação de quais objetos deverão pertencer a um determinado grupo feita na tarefa de agrupamento é de acordo com uma medida. Essa medida toma como base as características de cada objeto. Existem dois tipos básicos de medidas:

- Similaridade - mede quão semelhantes são dois objetos. Permite comparar  $n$  objetos diferentes a partir de  $p$  características observadas.
- Dissimilaridade - mede quão diferentes são dois objetos.

Assim, quanto maior o valor da medida de similaridade, mais semelhantes dois objetos são e quanto maior for a medida de dissimilaridade, mais diferentes são dois objetos.

De acordo com Braga (2005), as medidas de similaridade mais utilizadas podem ser de dois tipos:

- Baseadas na distância - utilizadas quando as características dos objetos são quantitativas, por exemplo, minutos, idade, distância, peso, altura, densidade.
- Baseadas na coincidência - utilizada quando as características dos objetos são qualitativas, por exemplo, sexo, cor, textura.

A vantagem de se trabalhar com medidas baseadas na distância é que basta satisfazer suas propriedades. A medida de distância é representada como o comprimento de um vetor entre dois pontos no espaço (BRAGA, 2005).

A medida de positividade é dada pela Equação 3.1:

$$d(X, Y) \leq 0 \quad (3.1)$$

A medida de simetria é representada pela Equação 3.2:

$$d(X, Y) = d(Y, X) \quad (3.2)$$

A medida de desigualdade triangular é representada pela Equação 3.3:

$$d(X, Y) + d(Y, Z) \geq d(X, Z) \quad (3.3)$$

Seja  $x \in X$  e  $y \in Y$ . De acordo com a Eq. (3.1), a distância entre  $x$  e  $y$  não pode ser um valor negativo. Já o cálculo da distância entre  $x$  e  $y$  deve ser igual ao cálculo da distância entre  $y$  e  $x$  como definido na Eq. (3.2). Seguindo a Eq. (3.3) define que, se  $z \in Z$ , a soma da distância entre  $x$  e  $y$  com a distância entre  $y$  e  $z$  essa distância tem que ser maior ou igual a distância entre  $x$  e  $z$ .

De acordo com Malhota (2004), dentre as medidas de distância mais utilizadas, as de maior destaque são:

- Distância Euclidiana: é calculada a partir da raiz quadrada da soma dos quadrados das diferenças dos valores para cada variável, como é descrito na Equação (3.4).

$$d(X, Y) = \sqrt{|a_{x1} - a_{y1}|^2 + |a_{x2} - a_{y2}|^2 + |a_{x3} - a_{y3}|^2 + \dots + |a_{xn} - a_{yn}|^2} \quad (3.4)$$

- Distância Manhattan: é calculada a partir da soma dos valores absolutos das diferenças para cada variável, como é descrito na Equação (3.5).

$$d(X, Y) = |a_{x1} - a_{y1}| + |a_{x2} - a_{y2}| + |a_{x3} - a_{y3}| + \dots + |a_{xn} - a_{yn}| \quad (3.5)$$

- Distância Chebychev: é calculada a partir da maior diferença de valores para qualquer variável, como pode ser visto na Equação (3.6).

$$d(X, Y) = \max(|a_{x2} - a_{x1}|, |a_{y2} - a_{y1}|) \quad (3.6)$$

### 3.1.2 Critérios de agrupamento

É importante salientar que um problema em aberto na área de agrupamento é a definição do número de agrupamentos. Para problemas em que esse número é conhecido, a priori, essa dificuldade não existe. Quando esse número não é conhecido, há métodos para definição automática desse parâmetro.

Outro parâmetro que tem grande impacto nos agrupamentos é a medida de similaridade.

A partir da escolha da medida de similaridade, é necessário escolher como os grupos serão formados. Para a formação dos grupos existem os seguintes métodos (BRAGA, 2005):

- Métodos hierárquicos: os agrupamentos são definidos a partir de uma sequência de fusões. A fusão reduz o número de agrupamentos em uma unidade a cada passo.
- Métodos de particionamento: é necessário definir o número de grupos que se deseja obter para classificar todos os objetos. Segundo Braga (2005), este método é o mais aplicado por exigir menor processamento ao ser utilizado em um volume de objetos considerável, principalmente, em casos da maioria dos atributos serem quantitativos.

### 3.1.3 Etapas da análise de agrupamento

Para realizar análise de agrupamento é necessário seguir os seguintes passos:

1. Obtenção da matriz de dados.
2. Padronização da matriz de dados (opcional).
3. Cálculo da matriz de distâncias de similaridade.
4. Aplicação do método de agrupamento.

Seguindo esses passos é possível agrupar qualquer conjunto de objetos baseado em suas características.

### 3.2 ALGORITMO *K-MEANS*

O algoritmo *K-Means*, também conhecido como *K-Médias*, é o mais aplicado em métodos de particionamento devido a sua simplicidade e obtenção de bons resultados (LINDEN, 2009).

O Algoritmo 1 apresenta o pseudocódigo do algoritmo *K-Means*.

---

#### **Algoritmo 1:** Pseudocódigo do algoritmo *K-Means*

---

**Entrada:** conjunto de objetos, número  $k$  de grupos

**Saída:**  $k$  grupos

**início**

    Selecione  $k$  objetos como sendo os centróides iniciais;

**repita**

        Compute  $k$  grupos atribuindo objetos que sejam o mais próximo do seu centróides;

        Recompute o centróide de cada grupo;

**até** os centróides não mudarem mais de grupo;

**fim**

---

Fonte: Winck (2012)

De fato, por ser veloz, o algoritmo *K-Means* geralmente converge em algumas dezenas de iterações.

### 3.3 ANÁLISE DE CONCEITOS FORMAIS

Análise de conceitos formais, FCA, do inglês, *Formal Concept Analysis*, é uma técnica matemática utilizada na extração de conceitos e estruturas de dados. Ela foi introduzida na década de 1980 e está sendo muito aplicada nas mais diversas áreas, (CINTRA et al., 2011), (MAJIDIAN; MARTIN; CINTRA, 2011), (CINTRA, 2012).

#### **3.3.1 Definições**

A estrutura da base de dados na análise de conceitos formais é o contexto formal, que é representado em forma de uma tabela em que as colunas representam os atributos e as linhas representam os objetos.

Em outras palavras, um contexto formal é uma representação da relação entre objetos e seus atributos. De acordo com a definição, os atributos em um contexto formal devem ser binários.

A tabela que representa o contexto formal, contém 1 (verdadeiro) na célula  $(i, j)$  se o objeto  $i$  tem o atributo  $j$ , e 0 (falso), caso contrário. A partir disso, é possível gerar uma estrutura conceitual do contexto formal. Uma estrutura conceitual é basicamente um gráfico cujos vértices correspondem aos conceitos formais representadas por conjuntos de exemplos ou atributos.

Formalmente, um contexto formal é uma tripla  $k = (G, M, I)$ , onde  $G$  é um conjunto de objetos,  $M$  é o conjunto de atributos e  $I$  é uma relação binária  $I \subseteq G \times M$ . Dado um conjunto de objetos  $A \subseteq G$ , a imagem compartilhada de  $A \in M$  é definida como:

$$A^\uparrow := \{m \in M \mid (g, m) \in I \forall g \in A\} \quad (3.7)$$

Enquanto a imagem compartilhada de  $B \in G$ , dado um conjunto de atributos  $B \subseteq M$ , é:

$$B^\downarrow := \{g \in G \mid (g, m) \in I \forall m \in B\} \quad (3.8)$$

O par  $(A, B)$  constitui um conceito formal de  $(G, M, I)$  se e somente se  $A \subseteq G, B \subseteq M$  e  $A = B^\downarrow, B = A^\uparrow$ .  $A$  é chamado de extensão do conceito e  $B$  é chamado de intenção do conceito (WILLE, 2009). Em outras palavras, a Equação 3.7 define a coleção de todos os atributos compartilhados por todos os objetos em  $A$ , enquanto a Equação 3.8 define a coleção de todos os objetos que compartilham todos os atributos em  $B$ .

### 3.3.2 Padronização de atributos para extração de conceitos formais

Tradicionalmente em análise de conceitos formais, a relação é binária, embora os contextos multivalorados são mais comuns que os binários. No entanto, para que os atributos nos contextos binários possam estender esse domínio de valores é necessária a idéia de escala conceitual. A escala conceitual transforma um

atributo multivalorado em atributo binário. Por exemplo, o atributo centímetros, cujo o domínio pode atingir de 0 a 200, pode gerar os seguintes atributos binários: altura-menor-que-50, altura-entre-50-e-100, altura-maior-que-100. Desde que os atributos gerados tenham como valores somente verdadeiro ou falso, eles podem ser utilizados no âmbito de análise de conceitos formais.

Usando o contexto formal, é possível gerar um reticulado conceitual que apresenta as informações de forma visual e agradável. Por exemplo, um brinquedo definido pela tabela *atributo x valor* apresentado na Tabela 3 que mostra o nome, idade, sexo e cor do cabelo de seis pessoas (CINTRA et al., 2011).

Tabela 3 – Tabela *atributo x valor* - exemplo do brinquedo.

<b>Nome</b>	<b>Idade</b>	<b>Sexo</b>	<b>Cor do Cabelo</b>
Andy	48	M	Preto
Lina	29	F	Preto
Mark	23	M	Marrom
Martina	46	F	Loiro
Mike	18	M	Marrom
Suzy	17	F	Loiro

O primeiro passo para definir o contexto formal é a criação dos atributos binários para representar a idade, o sexo e a cor do cabelo dos atributos da Tabela 3, como é apresentado na Tabela 4.

Tabela 4 – Contexto Formal baseado na Tabela 3.

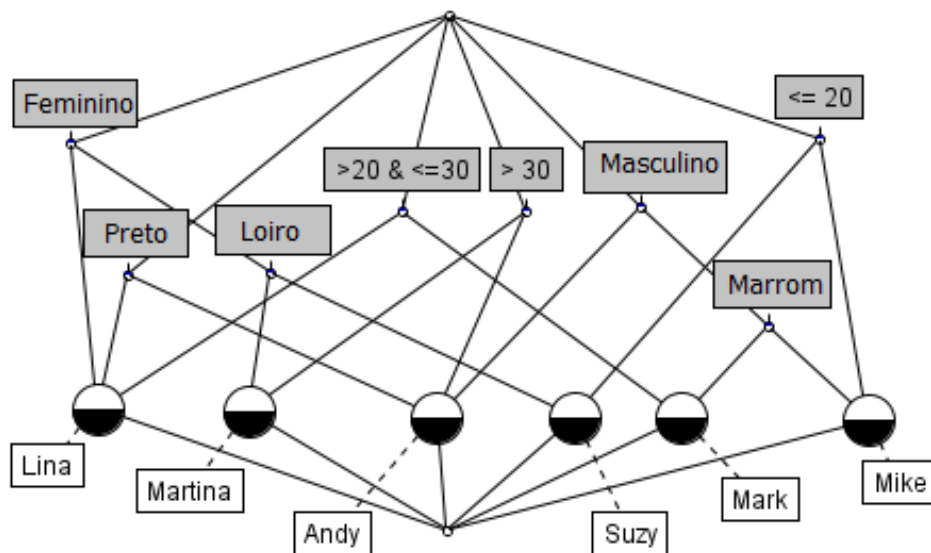
<b>Nome</b>	<b>Idade</b>			<b>Sexo</b>		<b>Cor do Cabelo</b>		
	$\leq 20$	$> 20 \leq 30$	$> 30$	M	F	Loiro	Marrom	Preto
Andy	0	0	1	1	0	0	0	1
Lina	0	1	0	0	1	0	0	1
Mark	0	1	0	1	0	0	1	0
Martina	0	0	1	0	1	1	0	0
Mike	1	0	0	1	0	0	1	0
Suzy	1	0	0	0	1	1	0	0

Na Tabela 4, o atributo contínuo idade foi discretizado, gerando três atributos. Os atributos multivalorados, sexo e cor do cabelo, geraram atributos binários para cada um de seus valores.

### 3.3.3 Reticulados conceituais

Os reticulados conceituais são modelos gráficos de fácil entendimento que apresentam informações com base nos conceitos formais extraídos dos dados. A Figura 3 apresenta o reticulado conceitual gerado a partir do contexto formal exibido na Tabela 4 com a distribuição dos objetos e seus respectivos atributos.

Figura 3 – Reticulado conceitual



Fonte: (CINTRA, 2012).

No reticulado conceitual da Figura 3, os conceitos formais são representados pelos nós. Os atributos são exibidos acima dos nós enquanto os objetos são exibidos abaixo dos nós. O posicionamento dos nós pode ser disposto de diversas maneiras. Na estrutura do reticulado, os nós estão dispostos de forma a minimizar o número de cruzamentos, assim, os atributos não são exibidos na ordem em que são apresentadas no contexto formal. Para recuperar as extensões, deve-se simplesmente traçar todos os caminhos que conduzem para baixo a partir do nó do atributo de interesse. Da mesma forma, é possível recuperar as intenções traçando todos os caminhos que conduzem a partir do nó que representa o objeto de

interesse. Por exemplo, a intenção do conceito formal representado pelo nó chamado *Mark* é o conjunto de atributos  $\{> 20 \ \& \ \leq 30, M, Marrom\}$ . A extensão do conceito formal representado pelo nó chamado *Loiro* é o conjunto de objetos *Martina, Suzy*.

Como foi dito anteriormente, a transformação de atributos contínuos em binários é vulgarmente chamado escala conceitual.

Desde que o contexto formal seja definido, os conceitos formais podem ser extraídos automaticamente. Na literatura, destaca-se o algoritmo *NextClosure* para a extração de conceitos formais que trabalha encontrando seus conceitos vizinhos (GANTER, 2002). Também pode-se citar o algoritmo proposto em (KRAJCA; OTRATA; VYCHODIL, 2010), que possui um processo de busca paralela. Desde o último conjunto de conceitos formais extraídos de um contexto formal é independente do algoritmo de extração, qualquer algoritmo irá produzir o mesmo conjunto de conceitos formais.

No próximo capítulo é apresentada uma revisão bibliográfica.



## 4 REVISÃO BIBLIOGRÁFICA

Esse capítulo apresenta os principais trabalhos relacionados à análise de agrupamento e análise de conceitos formais aplicados no processo de análise criminal.

### 4.1 TRABALHOS RELACIONADOS À ANÁLISE DA CRIMINALIDADE

Em Osgood (2000) exibe uma análise de índices criminais por meio da aplicação de regressão com base na distribuição de Poisson. Os índices de criminalidade foram calculados levando-se em consideração o tamanho da população, ou seja, neste caso, o número de infrações deve ser proporcional a quantidade de habitantes. O autor considera a aplicação da regressão de Poisson pelo fato de ser fundamentada na distribuição de erro, o que se caracteriza mais com a natureza do evento criminal. Trata-se de um trabalho com análise de dados criminais, porém pouco se pode descobrir acerca dos fatores que estão causando as ocorrências, ou os padrões que cercam o conjunto de crimes. Também não levam em consideração uma gama de dados que podem ser obtidos através dos registros, tornando os resultados apenas quantitativos.

### 4.2 TRABALHOS RELACIONADOS A DEFINIÇÃO DE *HOT SPOTS* CRIMINAIS COM USO DE ALGORITMOS DE AGRUPAMENTO

Em Chandra; Gupta; Gupta (2008), os autores consideraram a aplicação de análise de agrupamento em dados criminais visando obter séries temporais capazes de prever tendências do crime. Os autores afirmam que a vantagem de usar análise de agrupamento é poder trabalhar com um volume grande de dados e obter bons resultados com baixo custo computacional. Foi utilizado o modelo paramétrico de Minkowski para construir a matriz de distância aplicado no algoritmo *Dynamic Time Wrapping* (DTW). Os resultados obtidos forneceram informações para realizar a segregação de uma região de acordo com tipos criminais que se manifestam, atribuindo pesos para cada tipo criminal. Porém, não foi possível obter os locais ou pontos quentes de maior concentração criminal nessa separação e nem a visualização desses resultados plotados em um mapa.

Em Cruz (2010) foi realizada uma análise da criminalidade na capital do Tocantins, buscando compreender os padrões dos crimes distribuídos no espaço geográfico por meio da aplicação de um modelo empírico com regressão linear múltipla. O estudo considerou dois tipos de crime: crimes contra o patrimônio e crimes contra a pessoa. O autor também realizou seus estudos com dados reais obtidos a partir dos boletins de ocorrência. Apesar do trabalho ter como objetivo encontrar padrões criminais no espaço geográfico, os mapas gerados não contêm as informações sobre esses padrões, ou seja, diante dos locais de concentração criminal, não é possível identificar quais crimes são mais registrados, qual período do dia que se concentra as ocorrências criminais. A existência de relatórios com resultados apenas quantitativos podem ser obtidos a partir de modelos estatísticos, porém a identificação de padrões criminais com a geração de mapas para visualizar onde estão se concentrando esses padrões é um resultado de maior valor.

Em Musdholifah; Hashim; Wasito (2010) foi realizada análise de agrupamento com dados criminais aplicando um algoritmo iterativo conhecido como *Iterative Local Gaussian Clustering* (ILGC). O algoritmo ILGC combina os  $k$  vizinhos mais próximos com a densidade de *kernel* para definir seus grupos, visando obter melhores locais de forma iterativa. A validação dos resultados foi feita a partir da comparação com os métodos: Mapas Auto-Organizáveis e algoritmo *K-Means*. Os autores trabalharam com registros de ocorrências de roubo para determinar a geração dos grupos. No geral, a partir dos resultados obtidos foi possível obter os pontos de concentração criminal, apesar de considerar apenas um tipo criminal. Além disso, dos dois testes realizados, apenas no segundo teste é que a abordagem adotada pelos autores obteve melhor desempenho que o algoritmo *K-Means*.

Em Yu; Lay (2011) foi utilizada a densidade de *kernel* para detecção de *hot spots* criminais a partir dos registros criminais de roubos à residência. Esse estudo analisou uma base de dados com registros datados no período entre 1999 e 2007. Os resultados foram significativos com visualização de mapas em 3D devido à utilização da ferramenta ArcView. Foi possível detectar as manchas criminais, porém essas se referem a apenas um tipo criminal: roubo a residência. O trabalho dos autores poderia ter envolvido mais tipos criminais para realizar uma previsão mais condizente com a realidade, pois apenas um tipo criminal não demonstra a tendência criminal de uma cidade ou região, mas apenas de um crime.

Em Bordin; Lima (2012) foi realizada a implantação do projeto Mapa do Crime no ano de 2003 no estado do Paraná criando uma estrutura para armazenamento de um Boletim de Ocorrência Unificado. O objetivo deste trabalho era permitir que todos os dados coletados a partir de um registro de ocorrência em qualquer instituição de segurança pública, seja polícia civil ou militar, seguissem um padrão de armazenamento dos dados. Realizada essa implantação, tornou-se possível extrair maior número de informações. Porém, apesar de possuir uma estrutura mais condizente com o processo de análise criminal, pouco foi investido em técnicas computacionais ou modelos matemáticos capazes de identificar padrões e sugerir decisões para elaboração do planejamento estratégico. Apenas foi realizada a plotagem dos registros em um mapa, sem seguir nenhuma metodologia para isso.

#### 4.3 TRABALHOS RELACIONADOS AO ESTUDO DE MODELOS BASEADOS NA ANÁLISE DE CONCEITOS FORMAIS

Em Poelmans et al. (2010) é apresentada uma perspectiva diferente da análise de conceitos formais. O autor combinou os resultados obtidos por meio da análise de conceitos formais com HMM, do inglês, *Hidden Markov Models* e Mapas Auto-organizáveis. O HMM foi utilizado para obter, classificar e gerar séries temporais. Já os Mapas Auto-organizáveis permitem a visualização de um grande volume de dados mapeando-os de acordo com sua distribuição geográfica. O autor considerou crimes de violência doméstica, tráfico humano e ameaças terroristas. Trata-se de um trabalho que foi possível extrair padrões dos crimes considerados, além de inserir novas características capazes de refinar o processo de análise. Porém, os resultados são limitados a esses tipos de crime sem perspectivas de índices criminais.

Em Kester (2013b), o autor propôs um novo método de visualização de padrões da criminalidade com base em dados geográficos usando análise de conceitos formais, FCA, do inglês, *Formal Concept Analysis*. O autor considerou como o conjunto de atributos do contexto os tipos de crimes analisados e como seus objetos, os bairros da cidade. Logo, a identificação dos padrões por meio do reticulado permitiu extrair quais crimes se concentravam em determinados bairros. A desvantagem desse trabalho foi a falta de alguns atributos relacionado aos crimes,

tais como, horário, tipo do local onde o crime ocorreu, perfil das vítimas. Além disso, através dos resultados obtidos, não é possível analisar os índices criminais, ou seja, saber qual bairro é mais ou menos perigoso.

Em Kester (2013a), o autor também aplicou a análise de conceitos formais, mas dessa vez utilizou um conjunto maior de atributos para obter resultados melhores. Além dos crimes praticados, o autor utilizou dados dos criminosos como, sexo, idade, além de dados sobre o nível de escolaridade e da população em que o crime ocorreu. Nesse trabalho, o autor obteve resultados significativos, porém ainda não é possível identificar os níveis de criminalidade de cada bairro, impedindo que os órgãos de segurança pública identifiquem quais os bairros mais perigosos para redistribuir seus recursos de forma eficiente.

Nesse capítulo foram apresentados alguns trabalhos que propõe aplicações no contexto de análise criminal, nos quais análise de agrupamento e análise de conceitos formais podem ser utilizados. Apesar dos vários trabalhos encontrados na literatura, há necessidade de trabalhos que considerem as características das bases de dados de diferentes cidades, em especial Mossoró, e que combinem algoritmos de agrupamento e análise de conceitos formais.

O próximo capítulo mostra a metodologia usada neste trabalho.

## 5 METODOLOGIA PARA OBTENÇÃO DOS MODELOS DE APOIO À PREVENÇÃO E COMBATE A CRIMES

As principais etapas do desenvolvimento da proposta desse trabalho são:

1. Revisão bibliográfica.
2. Obtenção de dados reais.
3. Pré-processamento dos dados.
4. Obtenção de *hot spots* criminais com utilização do algoritmo *K-Means*.
5. Obtenção dos reticulados conceituais com utilização de análise de conceitos formais.
6. Obtenção do *ranking* de periculosidade a partir da combinação dos *hot spots* criminais e os reticulados conceituais.
7. Avaliação e validação dos modelos obtidos.
8. Divulgação do trabalho.

Os itens de 1 a 6 são descritos a seguir. Os itens 7 e 8 são descritos nos próximos capítulos.

### 5.1 REVISÃO BIBLIOGRÁFICA

Para a realização deste trabalho foi feita uma análise sobre o estado da arte cujo objetivo era conhecer técnicas computacionais mais utilizadas para processamento de dados criminais.

O Capítulo 4 apresenta e descreve as abordagens mais relevantes para esse trabalho.

### 5.2 OBTENÇÃO DE DADOS REAIS

Os dados aplicados nesse trabalho consistem em um conjunto de 7.486 registros de ocorrências obtidos da base original que continha 43.390 registros durante o período de dezembro/2011 a junho/2013 cedidos pelo Centro Integrado de Operações em Segurança Pública, CIOSP, de Mossoró-RN.

Esses dados foram obtidos com o apoio da Polícia Militar de Mossoró na pessoa do Major Carlos Macêdo que gentilmente cedeu os dados e deu apoio para a validação dos modelos.

A Tabela 5 apresenta a contabilidade dos registros obtidos.

Tabela 5 – Tabela de registros de ocorrências.

<b>Crime</b>	<b>Quantidade de registros</b>
Roubo	1.171
Furto	4.765
Homicídios	229
Tráfico	1.321
<b>Total</b>	<b>7.486</b>

Fonte: autoria própria.

A base original cedida para a realização do trabalho foi estruturada com nove atributos que compunham os registros de ocorrência, como descrito na Tabela 6.

Tabela 6 – Descrição dos atributos dos registros de ocorrências do Centro Integrado de Operações em Segurança Pública

<b>Atrib</b>	<b>Nome</b>	<b>Definição</b>
1	data	data de registro da ocorrência
2	hora	hora de registro da ocorrência
3	dow	código do dia da semana em que foi registrada a ocorrência
4	bairro	bairro em que aconteceu o crime
5	latitude	latitude em que o crime ocorreu
6	longitude	longitude em que o crime ocorreu
7	dispo	código de despachante da ocorrência
8	tycod	código do tipo criminal que foi registrado
9	typ-eng	tipo criminal que foi registrado

Fonte: autoria própria.

Como foi citado anteriormente, ver Seção 2.1, página 13, é possível observar que os dados apresentados na Tabela 6 possuem as informações

principais para caracterizar um crime, ou seja, o local, o horário e o crime realizado, além de outros atributos relacionados, tipo do local, sexo e idade dos criminosos e das vítimas e tipo de arma utilizada.

A partir dessas informações foi possível obter os locais de maior concentração criminal, os padrões dos crimes e um *ranking* dos bairros de acordo com o nível de periculosidade calculada.

### 5.3 PRÉ-PROCESSAMENTO DOS DADOS

Para que os dados existentes nos registros de ocorrência pudessem ser usados, foi necessária uma etapa de pré-processamento. Nessa etapa foram feitas as seguintes atividades:


1. Remoção de atributos que não acrescentavam informações de valor ao trabalho, tais como: *dispo* e *tycod*. Esses dados servem apenas para controle interno por parte do CIOSP.
2. Remoção de registros com alguns dos atributos principais faltantes (local, horário e crime).
3. Padronização dos dados para o formato *arff*, usado pela ferramenta WEKA (HALLN et al., 2009) que disponibiliza uma implementação do algoritmo *K-Means*.
4. Para a extração dos conceitos formais foi preciso transformar atributos multivalorados e contínuos em atributos binários. Essa tarefa, chamada de “*sealing*”, foi feita nessa etapa.
5. Padronização dos dados para o formato da ferramenta Conexp (YEVTUSHENKO, 2013) que disponibiliza os métodos necessários para a extração e visualização de conceitos formais.

Porém, para se trabalhar com análise de conceitos formais é necessário que os atributos que caracterizam uma ocorrência criminal sejam atributos univalorados ou binários, ou seja, que assumam V, para verdadeiro ou possui tal atributo, ou F, para falso ou não possui tal atributo.

Logo, para obter os resultados desejados com análise de conceitos formais foi preciso criar as escalas conceituais para os atributos *data*, *hora* e *typ-eng*.

De acordo com a Figura 4, pode ser vista a escala conceitual criada para o atributo data em que são gerados dois novos atributos binários.

Figura 4 – Definição do atributo "DATA" em termos de valores binários.

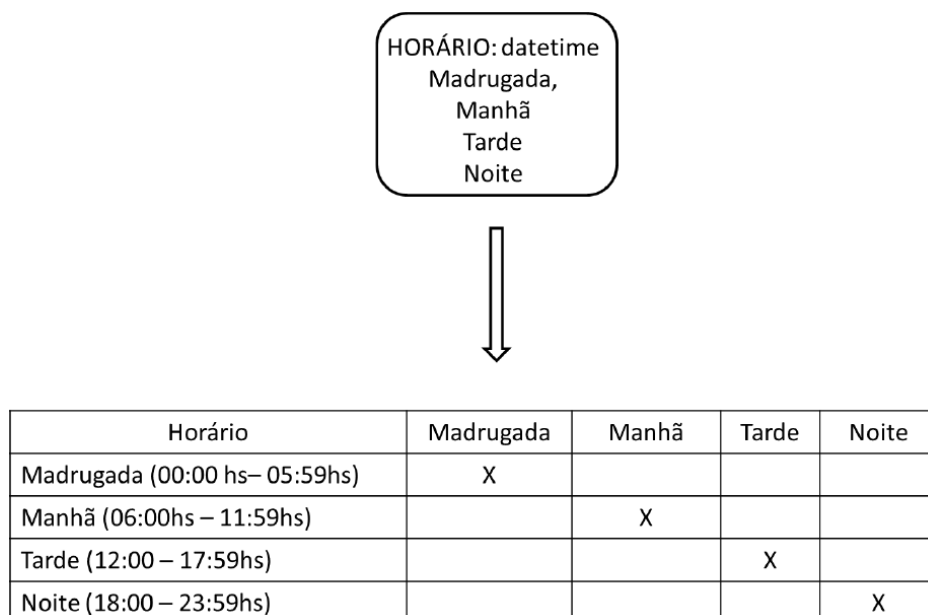


Fonte: autoria própria.

Como pode ser visto na Figura 4, o atributo data correspondia a data de ocorrência do crime, porém, para obtenção dos padrões, foi designado que a data poderia corresponder a um dia da semana ou um dia no final de semana. Logo, os dois valores possíveis para esse atributo seriam semana ou fim de semana. Assim, após a criação da escala conceitual para o atributo dia foram obtidos dois novos atributos, semana ou fim de semana, em que para cada um somente é possível os valores V ou F.

A Figura 5 apresenta a definição do atributo "HORÁRIO" em termos de valores binários.

Figura 5 – Definição do atributo "HORÁRIO" em termos de valores binários



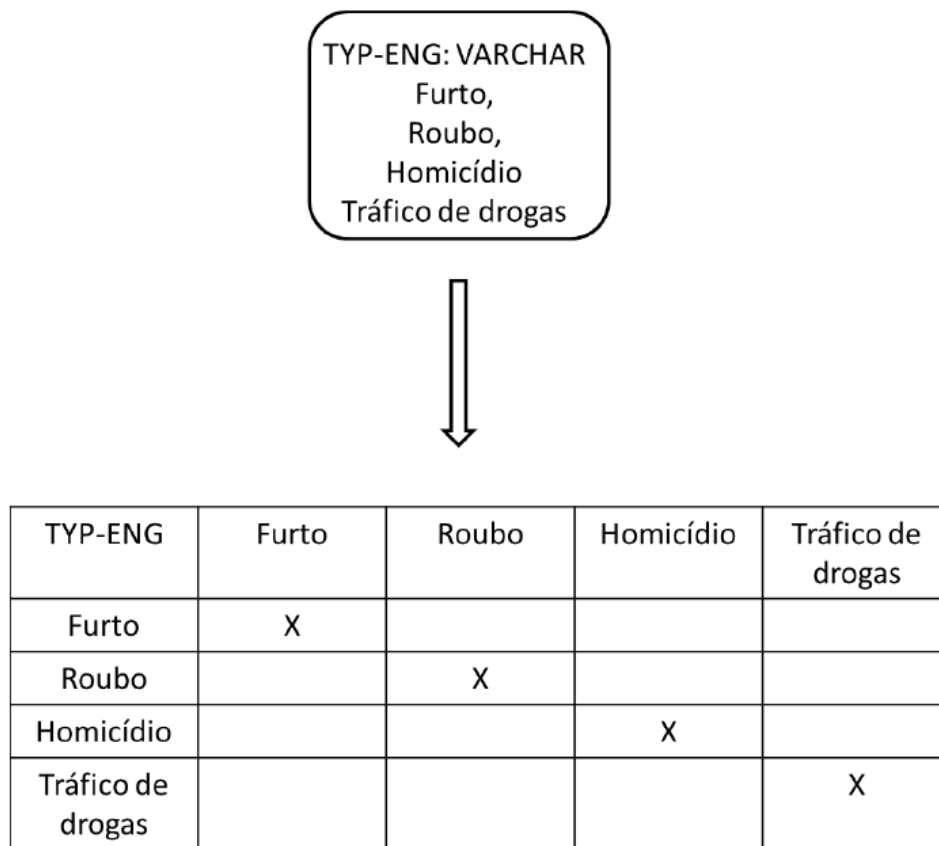
Fonte: autoria própria.



Foi definido, no trabalho, que os horários seriam divididos em intervalos de manhã (06:00hs às 11:59hs), tarde (12:00hs às 17:59hs), noite (18:00hs às 23:59hs) e madrugada (00:00hs às 05:59hs). Logo, os valores possíveis para o atributo horário eram manhã, tarde, noite e madrugada. Com a criação da escala conceitual para o atributo horário foram obtidos quatro novos atributos que podem assumir apenas V ou F.

Por último, a Figura 6 exibe a escala conceitual para o atributo typ-eng, definido na tabela original do CIOSP como o tipo de crime registrado na ocorrência.

Figura 6 – Definição do atributo "TYP-ENG" em termos de valores binários.



Fonte: autoria própria.

Esse atributo pode assumir 168 tipos de crime de acordo com a base oficial do CIOSP. Porém o foco desse trabalho são os crimes de furto, roubo, homicídio e tráfico. Os quatro atributos binários criados para o atributo typ-eng podem assumir apenas valores V (verdadeiro) ou F (falso).

Assim, após a criação dos atributos binários com bases nos atributos data, horário e typ-eng e suas respectivas remoções do trabalho, além da remoção

dos atributos *dispo* e *tycod*, a base utilizada ficou com a estrutura apresentada na Tabela 7.

Tabela 7 – Tabela de registros de ocorrências pré-processada.

<b>Atributos</b>	<b>Valores</b>
Semana	{V, F}
Fim de Semana	{V, F}
Madrugada	{V, F}
Manhã	{V, F}
Tarde	{V, F}
Noite	{V, F}
Bairro	Bairro em que aconteceu o crime
Latitude	Latitude em que aconteceu o crime
Longitude	Longitude em que aconteceu o crime
Furto	{V, F}
Roubo	{V, F}
Homicídio	{V, F}
Tráfico de Drogas	{V, F}

Fonte: autoria própria.

A Tabela 7 possui dez atributos binários que serviram para geração dos reticulados conceituais e os demais atributos serviram para obtenção dos *hot spots* criminais.

#### 5.4 OBTENÇÃO DE *HOT SPOTS* CRIMINAIS COM UTILIZAÇÃO DO ALGORITMO *K-MEANS*

A obtenção dos locais com maior número de ocorrências é um dos principais resultados da análise criminal. Por meio da análise de agrupamento é possível particionar o conjunto de dados em grupos que consistem em registros com padrões semelhantes. Obtendo-se, assim, os *hot spots* criminais.

Como mencionado anteriormente, para a obtenção dos *hot spots* criminais foi utilizado o algoritmo *K-Means* devido a obtenção de bons resultados e seu custo e benefício.

Os resultados deste trabalho foram obtidos utilizando o pacote `weka.clusteres.SimpleKMeans` do WEKA com as seguintes configurações do ambiente:

- Medida de distância: distância euclidiana
- Número máximo de iterações: 500
- Quantidade de grupos: os testes levaram em consideração 8 a 20 grupos.

Os experimentos com agrupamentos foram divididos pelo período do dia.

O objetivo dessa divisão é a possibilidade de obter diferentes *hot spots* criminais para cada período do dia para facilitar o planejamento da distribuição dos recursos: viaturas e policiais para o patrulhamento previsto. Assim, pelo período da manhã são obtidos os *hot spots* criminais para serem patrulhados, enquanto que no período da tarde a concentração de *hot spots* criminais podem ser diferente, conseqüentemente, a rota de patrulhamento pode ser ajustada.

Além da realização de experimentos separados pelos períodos do dia, os experimentos foram realizados usando diferentes números de agrupamentos. Esses números foram definidos, entre 8 e 20, levando em conta os diversos recursos que podem ser distribuídos, como por exemplo, viaturas, policiais, câmeras de segurança, entre outros.

Logo, de acordo com a disponibilidade de recursos, viaturas, por exemplo, é possível abranger os locais de maior concentração criminal tornando o planejamento mais eficiente.

Os *hot spots* criminais obtidos continham duas informações básicas: a latitude e a longitude referente ao bairro.

A partir da obtenção dos *hot spots* criminais foi realizado a plotagem dos mesmos com base em suas coordenadas geográficas. Os *hot spots* criminais foram plotados em um mapa da cidade de Mossoró com o auxílio de uma aplicação disponível no Google Maps (GOOGLE, 2014). Os resultados foram mapas com diferentes números de *hot spots* criminais para os quatro períodos do dia. Tais mapas são fáceis de serem interpretados e permitem uma rápida compreensão da situação de crimes na cidade.

## 5.5 OBTENÇÃO DOS RETICULADOS CONCEITUAIS COM UTILIZAÇÃO DE ANÁLISE DE CONCEITOS FORMAIS.

O objetivo de utilizar análise de conceitos formais foi de obter os reticulados conceituais que revelassem padrões no conjunto de registros de ocorrências de acordo com as características que compreendem os crimes.

A obtenção dos reticulados conceituais foi possível através do ambiente Conexp, *Concept Explorer*, uma ferramenta de código aberto implementada em linguagem JAVA (TILLEY, 2004).

A ferramenta Conexp permite a extração de conceitos formais que são então usados para a definição dos reticulados conceituais.

Os reticulados conceituais gerados pelo Conexp permitem:

- Diferenciar o tamanho da extensão de um conceito, ou seja, quanto maior a quantidade de objetos que compreende um conceito, maior é o nó correspondente.
- Destacar os conjuntos de nós, exibindo informações como a quantidade de objetos e a intenção dos conceitos.
- Ajustar o posicionamento dos conceitos de forma a facilitar a leitura e interpretação dos mesmos.
- Alterar o reticulado de acordo com os atributos selecionados.

Com esses recursos foi possível gerar modelos simples de entendimento, fácil e rápido de serem usados e com informação útil sobre os padrões de criminalidade na cidade de Mossoró.

Assim, foram realizados diferentes experimentos com o objetivo de identificar vários padrões criminais. Esses experimentos são discutidos a seguir:

- Reticulados obtidos a partir de todos os registros – esse teste levou em consideração todos os registros da base, ou seja, registros com furto, roubo, homicídio e tráfico, e em todos os períodos do dia, ou seja, manhã, tarde, noite e madrugada. O objetivo desse teste foi de identificar os diferentes índices criminais para cada período do dia.
- Reticulados obtidos a partir de todos os registros para cada período do dia – esses modelos foram gerados usando todos os registros da base,

ou seja, registros de furto, roubo, homicídio e tráfico, em cada período do dia. Esses modelos permitem identificar as diferenças de índices criminais para cada período do dia.

- Reticulados obtidos a partir de todos os registros para todos os períodos do dia – esses modelos foram gerados usando cada registro da base, ou seja, apenas um tipo criminal em todos os períodos do dia. Esses modelos permitem identificar as diferenças de índices de cada crime para todos os períodos do dia.
- Reticulados obtidos a partir de todos os registros para todo o período do dia para cada bairro - esses modelos foram gerados usando todos os registros da base, ou seja, registros com furto, roubo, homicídio e tráfico, e em todos os períodos do dia, ou seja, manhã, tarde, noite e madrugada, referentes a cada bairro. Esses modelos permitem identificar os diferentes índices criminais para cada período do dia em cada bairro.
- Reticulados obtidos a partir de todos os registros para cada período do dia para cada bairro – esses modelos foram gerados usando todos os registros da base, ou seja, registros com furto, roubo, homicídio e tráfico, e cada período do dia, referente a um bairro. Esses modelos permitem identificar as diferenças de índices criminais para cada período do dia em cada bairro.
- Reticulados obtidos a partir de cada registro para todos os períodos do dia – esse modelo foi gerado usando cada registro da base, ou seja, apenas um tipo criminal em todos os períodos do dia. Esses modelos permitem identificar as diferenças de índices de cada crime para todos os períodos do dia em um bairro.

## 5.6 DEFINIÇÃO DA CLASSIFICAÇÃO DE PERICULOSIDADE DOS BAIRROS DE MOSSORÓ A PARTIR DA COMBINAÇÃO DOS *HOT SPOTS* CRIMINAIS E RETICULADOS CONCEITUAIS

Foi possível elaborar um *ranking* dos bairros de Mossoró a partir dos seus níveis de periculosidade.

A plotagem dos *hot spots* criminais nos mapas permitiu a visualização dos bairros com maior concentração criminal. A partir desse ponto, com a obtenção dos reticulados foram definidas fórmulas para determinar o nível de periculosidade de cada bairro.

Para a obtenção desses cálculos foi levada em consideração que os tipos criminais possuem níveis de periculosidade diferentes (MIRANDA et al., 2008). Logo, um crime do tipo furto é considerado menos perigoso que um crime do tipo homicídio. A Tabela 8 mostra o fator de periculosidade de cada crime e o cálculo do peso que ele acrescenta ao nível de periculosidade de um bairro.

Tabela 8 – Cálculo do fator de periculosidade.

<b>Crime</b>	<b>Fator</b>	<b>Peso</b>
Furto (F.furto)	1	peso do furto = (fator de periculosidade dos furtos) * (número de ocorrências de furtos)
Roubo (F.roubo)	2	peso do roubo = (fator de periculosidade dos roubos) * (número de ocorrências de roubos)
Homicídio (F.homicídio)	3	peso do homicídio = (fator de periculosidade dos homicídios) * (número de ocorrências de homicídios)
Tráfico (F.trafico)	4	peso do tráfico = (fator de periculosidade do tráfico) * (número de ocorrências de tráfico)

Fonte: autoria própria.

Usando-se os pesos descritos anteriormente, o índice criminal de cada bairro é calculado de acordo com a Equação 5.1.

$$peso.total = peso.furto + peso.roubo + peso.homicidio + peso.trafico \quad (5.1)$$

Como o número de ocorrências de cada tipo de crime apresenta grandes variações, ver Tabela 7, o nível de periculosidade dos bairros foi normalizado de acordo com a Equação a seguir:

$$\text{nivel. periculosidade} = \frac{\text{peso. furto} + \text{peso. roubo} + \text{peso. homicidio} + \text{peso. trafico}}{\text{peso. total}} \quad (5.1)$$

## 5.7 AVALIAÇÃO E VALIDAÇÃO DOS MODELOS OBTIDOS

Todos os resultados obtidos foram analisados por especialistas da área que forneceram *feedback* positivo e contribuíram com sugestões para o aperfeiçoamento dos modelos.

As considerações dos especialistas foram avaliadas em termos da precisão de posicionamento dos *hot spots* criminais e dos padrões dos crimes obtidos. Logo, ao avaliar como positivo o *feedback* dos especialistas significa dizer que os *hot spots* obtidos foram localizados em regiões consideradas perigosas pelos policiais. O mesmo critério de avaliação foi utilizado para os padrões dos crimes, ou seja, os especialistas confirmaram que os padrões obtidos de fato tem se manifestado na cidade de Mossoró.

No contexto global, os especialistas consideraram os resultados dos modelos coerentes no que se refere à distribuição dos *hot spots* criminais de acordo com a percepção dos mesmos adquirida no trabalho diário. De fato, os locais tradicionalmente perigosos, foram ressaltados no mapa, porém locais considerados tradicionalmente tranquilos também apareceram. Isso se deve ao fato de que diferentes profissionais atuam em diferentes horários, dificultando a percepção da cena de criminalidade como um todo.

Os especialistas também sugeriram experimentos para geração de modelos em meses de festividades na cidade, como complemento ao trabalho feito. Todos os experimentos realizados, incluindo os específicos para os meses de festividades, são descritos no próximo capítulo.

## 6 RESULTADOS

Nesse capítulo são apresentados os modelos gerados para definição de *hot spots* criminais e reticulados conceituais, além do *ranking* de periculosidade dos bairros da cidade de Mossoró-RN.

### 6.1 HOT SPOTS CRIMINAIS

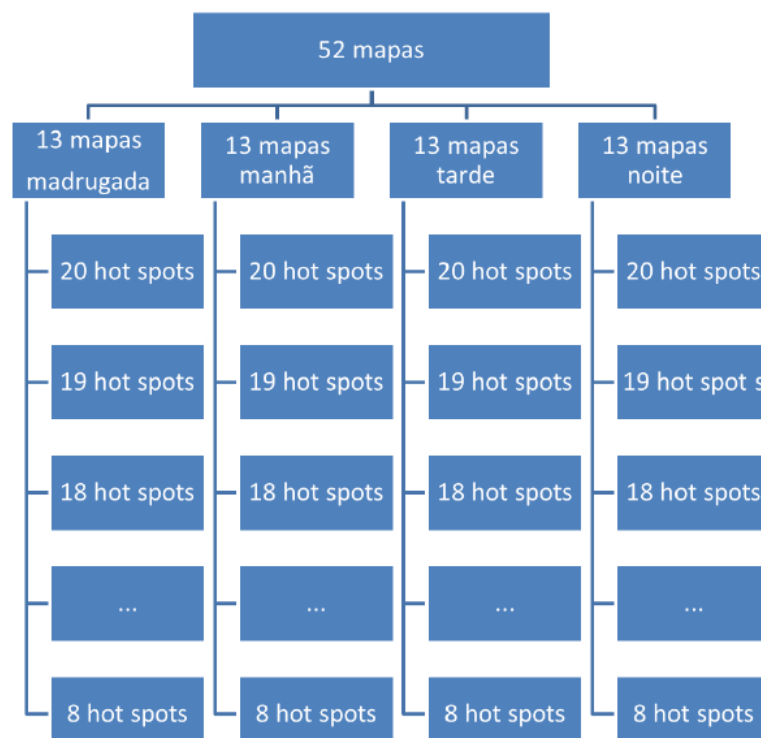
No total, foram gerados 52 mapas de *hot spots* criminais de acordo com:

- Período do dia - manhã, tarde, noite e madrugada.
- Número de *hot spots*, variando entre 8 e 20 *hot spots* criminais.

A Figura 7 apresenta um sumário dos 52 mapas de *hot spots* criminais pelos quatro períodos do dia, em que cada mapa conta com 8 a 20 *hot spots* criminais. A seguir são apresentados os mapas gerados para experimentos com 12 *hot spots* criminais para os quatro períodos do dia.

Os demais mapas são apresentados no Anexo A.

Figura 7 – *Hot Spots* criminais obtidos com o algoritmo k-Means.



Fonte: autoria própria.

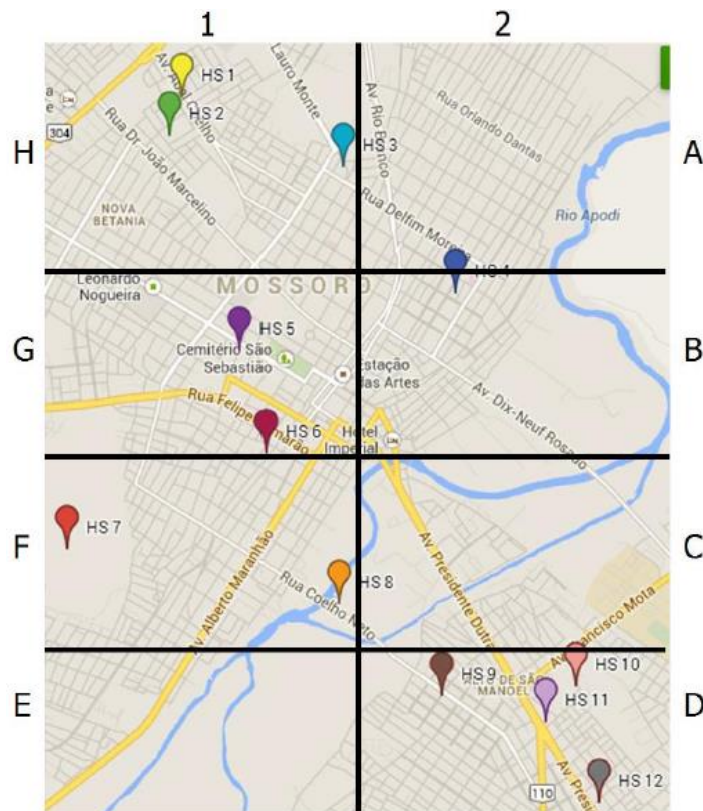


Como mostrado na Figura 7, foram feitos 13 experimentos para cada período do dia. Assim, para cada período do dia foram obtidos 182 *hot spots* criminais.

Com a identificação dos *hot spots* criminais e a plotagem das coordenadas geográficas, foi possível analisar em quais bairros se concentraram as ocorrências criminais no período da análise, ou seja, o ano de 2012.

Assim, a Figura 8 exhibe o mapa obtido a partir da plotagem de 12 *hot spots* criminais no período da madrugada.

Figura 8 – *Hot Spots* criminais obtidos no período da madrugada.

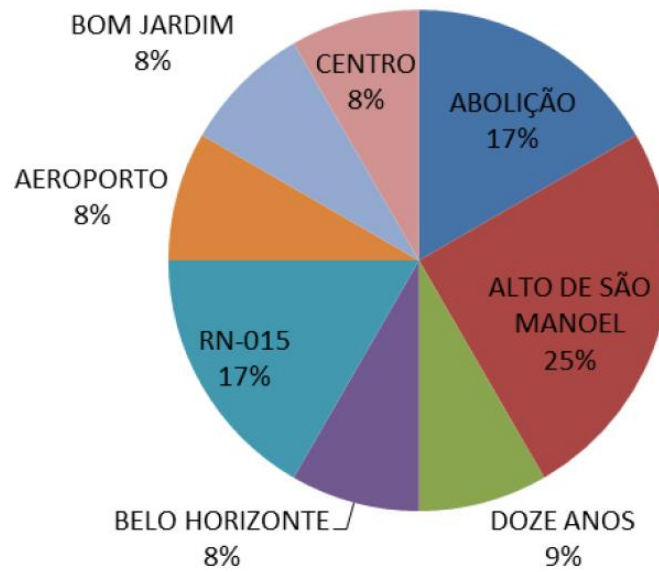


Fonte: autoria própria.

A Figura 8 mostra que um dos bairros com maior concentração de *hot spots* criminais é o Alto de São Manoel, no quadrante D2. De fato, é de conhecimento dos moradores de Mossoró que esse bairro é perigoso. Porém, os *hot spots* criminais contém informações mais precisas, como local exato dos centros de alta concentração de crimes.

A distribuição dos *hot spots* criminais no mapa, referente ao período da madrugada, de acordo com os bairros é mostrado na Figura 9.

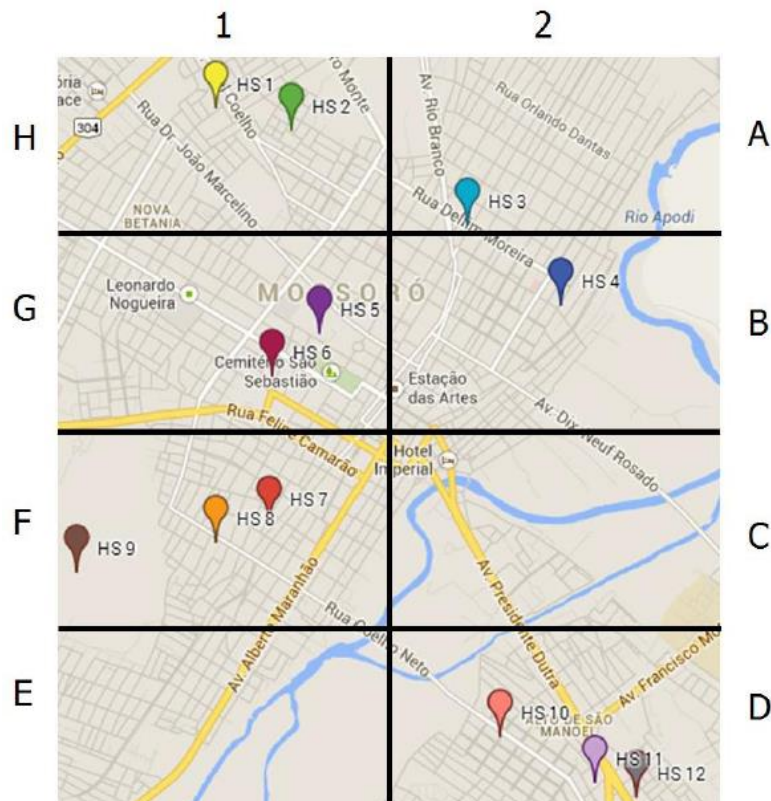
Figura 9 – Distribuição dos *hot spots* criminais obtidos no período da madrugada.



Fonte: autoria própria.

A Figura 10 exibe o mapa obtido a partir da plotagem de 12 *hot spots* criminais no período da manhã.

Figura 10 – *Hot Spots* criminais obtidos no período da manhã.




Fonte: autoria própria.

De acordo com a Figura 10, é possível observar que a distribuição dos *hot spots* criminais são semelhantes nos bairros Belo Horizonte, quadrante F1, e Alto de São Manoel, quadrante D2.

A distribuição dos *hot spots* criminais no mapa, referente ao período da manhã, também pode ser visualizada na Figura 11.

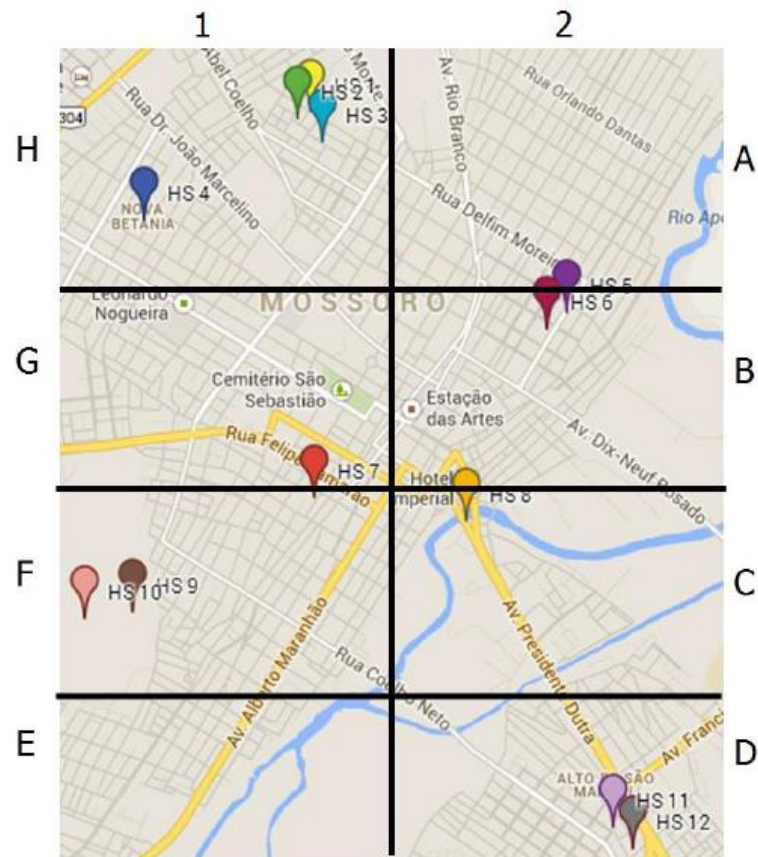
Figura 11 – Distribuição de *Hot Spots* criminais no período da manhã.



Fonte: autoria própria.

A Figura 12 exibe o mapa obtido a partir da plotagem de 12 *hot spots* criminais no período da tarde.

Figura 12 – *Hot Spots* criminais obtidos no período da tarde




Fonte: autoria própria.

De acordo com a Figura 12, é possível observar que a distribuição dos *hot spots* criminais mostra uma concentração maior no bairro Abolição, quadrante H1, e menor no bairro Alto de São Manoel, quadrante, D2.

A distribuição dos *hot spots* criminais no mapa, referente ao período da tarde, também pode ser visualizada na Figura 13.

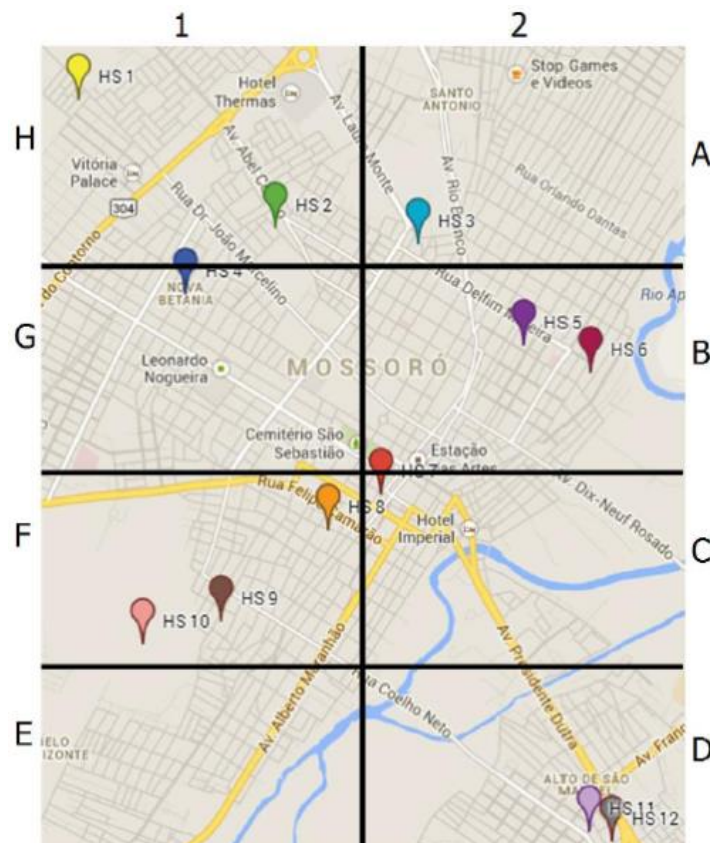
Figura 13 – Distribuição de *Hot Spots* criminais no período da tarde.



Fonte: autoria própria.

A Figura 14 exibe o mapa obtido a partir da plotagem de 12 *hot spots* criminais no período da noite.

Figura 14 – *Hot Spots* criminais obtidos no período da noite.

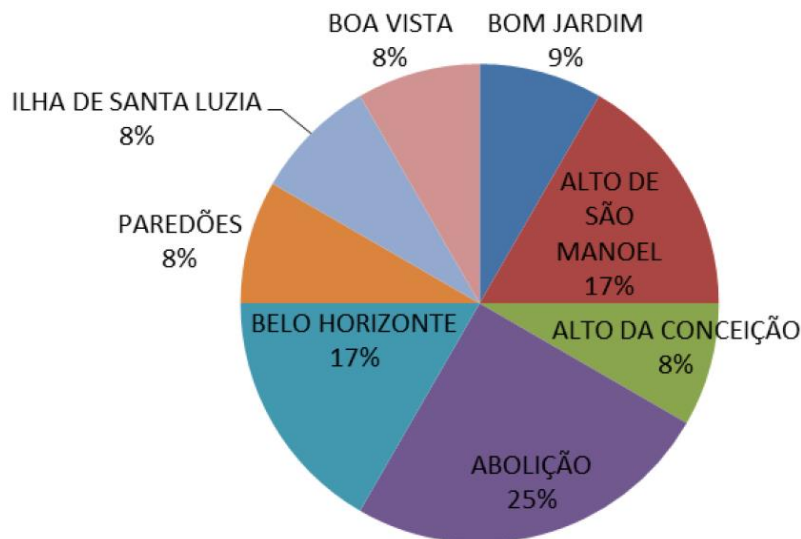


Fonte: autoria própria.

De acordo com a Figura 14, é possível observar que a distribuição dos *hot spots* criminais também mostra uma distribuição semelhante no bairro Belo Horizonte, quadrante F1, e no bairro Abolição, quadrante H1.

A distribuição dos *hot spots* criminais no mapa, referente ao período da noite, também pode ser visualizada na Figura 15.

Figura 15 – Distribuição de *Hot Spots* criminais no período da noite.



Fonte: autoria própria.

Com a análise dos mapas com os *hot spots* criminais é possível observar que existe uma migração do crime durante o dia. Isso porque, no decorrer do dia, os bairros de maior concentração criminal foi sendo modificado, como no caso do período da madrugada que tinha como bairro mais perigoso o Alto de São Manoel e a noite esse bairro seria Abolição. Com esse tipo de informação, é possível traçar um planejamento estratégico que acompanhe essa migração, permitindo que o patrulhamento policial seja mais apropriado afim de prevenir a ocorrência criminal, como é pretendido neste trabalho.

De acordo com as orientações dos especialistas, foi feita uma análise mensal durante o ano de 2012 para verificar se nos períodos de atividades festivas, junho e dezembro, apresentam maior concentração criminal em bairros distintos na cidade dos anteriormente citados.

Para avaliar tal situação, a Tabela 9 apresenta a quantidade de registros de ocorrências para cada mês do ano de 2012 referente aos crimes de furto, roubo, homicídio e tráfico.

Tabela 9 – Registros de Ocorrências Mensais no ano de 2012.

<b>Mês</b>	<b>Quantidade de Registros</b>	<b>Desvio Padrão</b>
Janeiro	2135	295
Fevereiro	2382	48
Março	1245	1185
Abril	687	1743
Maio	3045	-615
Junho	3061	-631
Julho	2780	-350
Agosto	2779	-349
Setembro	2687	-257
Outubro	2699	-269
Novembro	2599	-169
Dezembro	3060	-630
Média	2430	

Fonte: autoria própria.

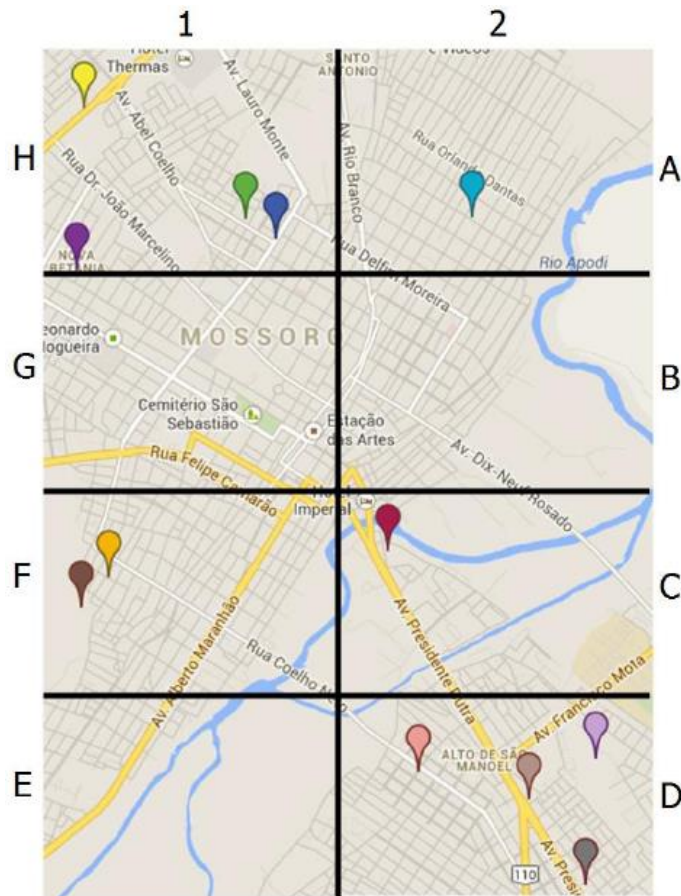
Analisando a Tabela 9 é possível observar que os períodos de atividades festivas recomendados pelos especialistas realmente apresentam taxas de crimes maiores que nos outros meses.

Assim, para esses períodos foram gerados os mapas com *hot spots* criminais para identificar os locais de maior concentração criminal e permitir uma melhor comparação.

Os experimentos adicionais usaram 12 *hot spots* criminais por restrições de tempo

A Figura 16 apresenta a distribuição de 12 *hot spots* criminais no mês de junho de 2012.

Figura 16 – Distribuição dos *Hot Spots* criminais no mês de junho de 2012.




Fonte: autoria própria.

De acordo com o mapa da Figura 16 é possível observar que apareceram concentrações de *hot spots* criminais semelhantes nos bairros Abolição, quadrante H1, e Alto de São Manoel, quadrante D2.

A Figura 17 apresenta a distribuição dos percentuais de cada bairro.



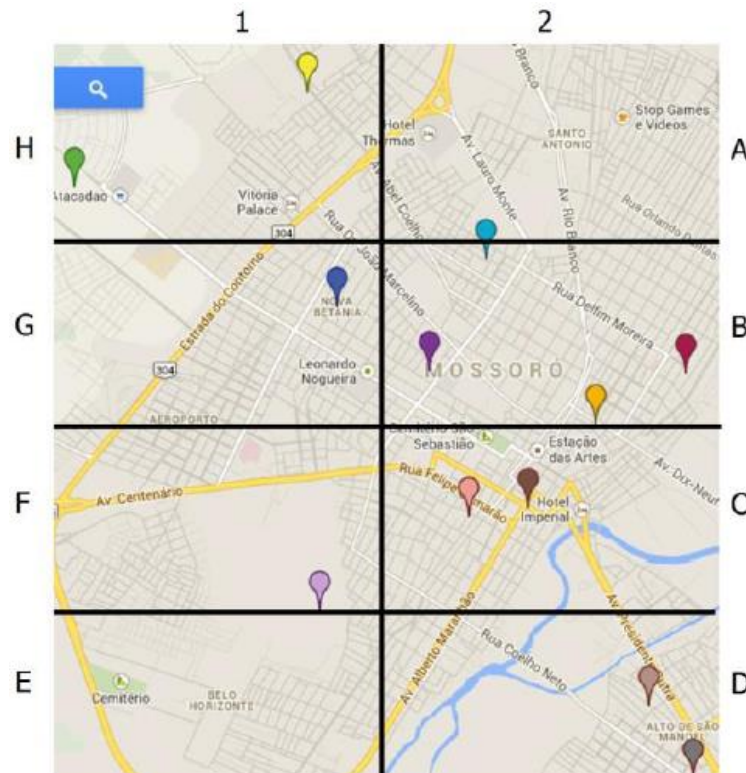
Figura 17 – Distribuição dos *Hot Spots* criminais em junho de 2012.



Fonte: autoria própria.

A Figura 18 apresenta a distribuição de 12 *hot spots* criminais no mês de dezembro no ano de 2012.

Figura 18 – Distribuição dos *Hot Spots* criminais no mês de Dezembro de 2012.




Fonte: autoria própria.

O mapa da Figura 18 é apresentada uma distribuição uniforme dos *hot spots* criminais.

De acordo com a Figura 19, é possível observar o percentual de cada bairro.

Figura 19 – Distribuição dos *Hot Spots* criminais em Dezembro de 2012.



Fonte: autoria própria.

Logo, de acordo com essas análises, durante o planejamento estratégico pode-se ter essa noção de migração da concentração criminal, sabendo, previamente, para quais locais deve ser posicionado o patrulhamento.

## 6.2 RETICULADOS CONCEITUAIS

A utilização de análise de conceitos formais permitiu a geração de modelos de reticulados conceituais com informações sobre a atividade criminal em Mossoró-RN.

Esses modelos padrões foram gerados a partir dos conceitos formais obtidos dos registros criminais cedidos pelo CIOSP.

A partir dos reticulados conceituais e dos *hot spots* criminais é possível otimizar o planejamento estratégico da polícia.

A partir de cada nó, que apresenta um conceito formal, é possível saber quantos objetos (registros de ocorrências) o formam e quais os atributos o compreende, ou seja, é possível identificar a extensão e intensão do conceito, respectivamente.

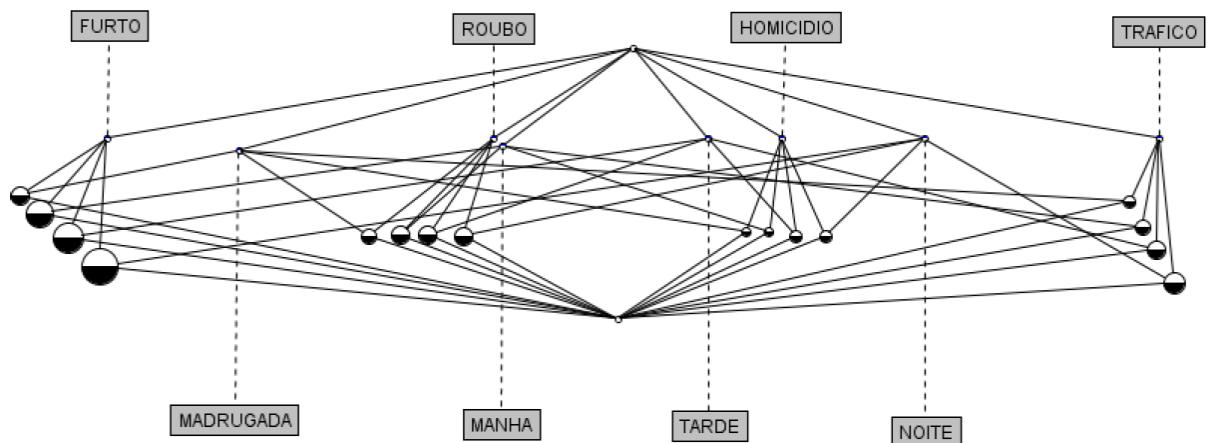
Basicamente, foram gerados três modelos distintos:

1. Reticulados com a distribuição de crimes por período do dia.
2. Reticulados com a distribuição dos crimes por bairro.
3. Reticulados com a distribuição dos crimes por período em cada bairro.

Esses modelos são descritos a seguir.

A Figura 20 mostra o reticulado conceitual obtido a partir de todos os registros de furto, roubo, homicídio e tráfico para todos os períodos.

Figura 20 – Reticulado Conceitual de Crime por Período.



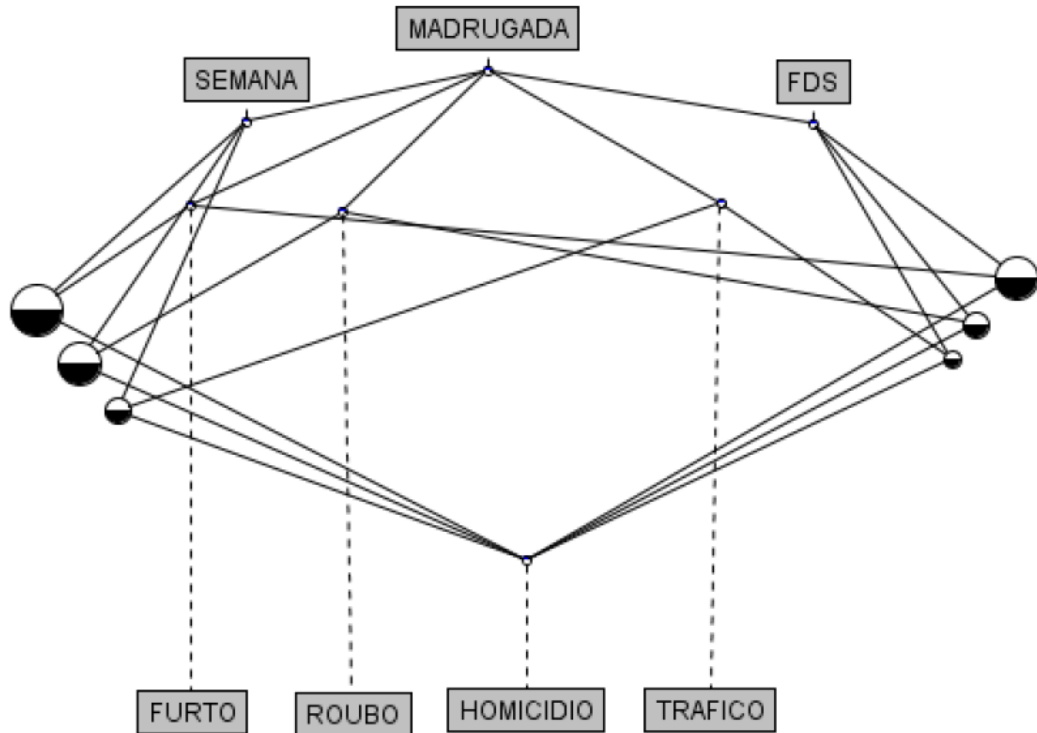
Fonte: autoria própria.

Note que o tamanho dos nós é proporcional ao número de registros envolvidos. Assim é fácil observar a distribuição de cada crime pelo período do dia.

A Figura 20 mostra que o período noturno é o que apresenta maior número de registros para todos os tipos de crimes. Os crimes de roubo costumam se manifestar no período da manhã, enquanto que os crimes de homicídios possuem uma distribuição uniforme ao longo do dia. Por fim, os crimes de tráfico se manifestam mais no período noturno.

A Figura 21 apresenta o reticulado conceitual obtido dos crimes de homicídios, considerando todos os períodos, no bairro Alto de São Manoel.

Figura 21 – Reticulado Conceitual de Homicídios no Alto de São Manoel.

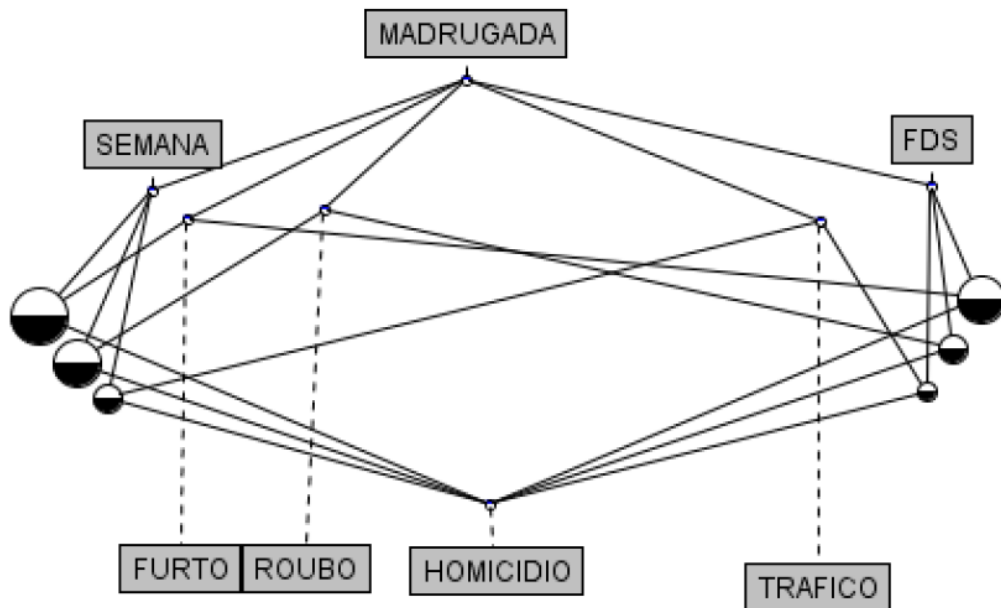


Fonte: autoria própria.

Analisando o reticulado da Figura 21 pode-se inferir que não ocorre manifestação de homicídios durante o fim de semana e no período da madrugada no bairro Alto de São Manoel. Durante o fim de semana, os homicídios se concentram no período da manhã e da madrugada. Enquanto isso, durante a semana, os homicídios mais no período da madrugada.

A Figura 22 exibe o reticulado conceitual obtido a partir de todos os registros criminais considerando o período da madrugada no bairro Alto de São Manoel.

Figura 22 – Reticulado Conceitual com todos os Crimes no período da Madrugada no bairro Alto de São Manoel.



Fonte: autoria própria.

A partir da Figura 22 pode-se prever que diante de uma ocorrência criminal a primeira ideia é o crime de furto, devido sua concentração ser maior tanto na semana, quanto no fim de semana. Com a observação do reticulado, é possível perceber que não foram registrados crimes de homicídios no período da madrugada no bairro Alto de São Manoel.

Logo, com a análise de reticulados conceituais é possível a extração de padrões que se manifestam nos registros de ocorrências.

### 6.3 RANKING DE PERICULOSIDADE

A partir da identificação dos *hot spots* criminais e da obtenção dos reticulados conceituais foi possível calcular um nível de periculosidade para cada bairro e classificá-los, gerando um *ranking*.

Também foi elaborada outra classificação afim de tipificar cada bairro mediante seus níveis de periculosidade. Os critérios adotados foram:

- Muito perigoso - nível de periculosidade entre 0.4 e 1.
- Perigoso - nível de periculosidade entre 0.2 e 0.39.
- Pouco perigoso - nível de periculosidade entre 0 e 0.19.

A Tabela 10 apresenta o ranking de periculosidade obtido para os bairros da cidade de Mossoró.

Tabela 10 – Ranking de Periculosidade.

<b>Bairro</b>	<b>Nível de Criminalidade</b>	<b>Classificação</b>
Abolição	1	Muito Perigoso
Centro	1	Muito Perigoso
Santo Antônio	0,94	Muito Perigoso
Alto de São Manoel	0,82	Muito Perigoso
Aeroporto	0,68	Muito Perigoso
Santa Delmira	0,54	Muito Perigoso
Dom Jaime Câmara	0,51	Muito Perigoso
Nova Betânia	0,51	Muito Perigoso
Bom Jardim	0,39	Perigoso
Rincão	0,39	Perigoso
Belo Horizonte	0,38	Perigoso
Boa Vista	0,37	Perigoso
Planalto Treze Maio	0,37	Perigoso
Alto da Conceição	0,27	Perigoso
Doze Anos	0,23	Perigoso
Paredões	0,23	Perigoso
Alto do Sumaré	0,2	Perigoso
Presidente Costa e Silva	0,2	Perigoso
Barrocas	0,19	Perigoso
Pintos	0,14	Pouco Perigoso
Redenção	0,12	Pouco Perigoso
Ilha de Santa Luzia	0,1	Pouco Perigoso
Bom Jesus	0,09	Pouco Perigoso
Lagoa do Mato	0,08	Pouco Perigoso
Diz-Sept Rosado	0,05	Pouco Perigoso
Itapetinga	0,01	Pouco Perigoso
Alagados	0	Pouco Perigoso

Fonte: autoria própria.

Observando a Tabela 10, o bairro Barrocas por estar na borda da divisão, foi classificado como *Perigoso*.

A partir desse conjunto de resultados é possível definir estratégias mais eficientes de combate a criminalidade, otimizando a distribuição dos recursos policiais, bem como facilitar o trabalho dos analistas criminais investindo em técnicas mais eficazes.

#### 6.4 ANÁLISE DOS MODELOS POR ESPECIALISTAS

A partir da obtenção dos *hot spots* criminais, dos reticulados conceituais e do *ranking* de periculosidade foi possível apresentar tais resultados para os especialistas da área, policiais do CIOSP.

Inicialmente, o *feedback* foi considerado positivo. Foram feitas sugestões pelos especialistas, a fim de comprovar a validade dos resultados, em que eles pediram a realização dos experimentos nos períodos de atividades festivas, junho e dezembro. De acordo com a análise dos especialistas, os modelos gerados foram avaliados como:

- Consistentes, pois refletem a realidade da cidade de Mossoró-RN.
- Coerentes e válidos, pois refletem o conhecimento adquirido pelos mesmos no trabalho diário.
- Inovadores, pois apresentam modelos novos com informações úteis.
- Fácil compreensão, pois os modelos são gráficos e visuais, facilitando a compreensão dos mesmos e agilizando o processo de avaliação dos dados.
- Fácil aplicação, pois os modelos são gerados rapidamente e podem ser usados no planejamento anual, mensal ou até mesmo semanal facilmente.

Logo, mediante o retorno dos especialistas, os resultados obtidos são capazes de identificar e posicionar os locais de maior concentração, além de obter os padrões condizentes com a realidade observada pelos policiais.

A seguir são apresentadas as conclusões e trabalhos futuros.

## 7 CONSIDERAÇÕES FINAIS

A análise da grande quantidade de dados criminais é uma tarefa altamente relevante para a prevenção e combate ao crime. Essa tarefa também permite uma economia de recursos públicos ao servir como base para planejamentos estratégicos direcionados às características da criminalidade em cada localidade.

Os investimentos na área de inteligência e análise criminal tem sido baixo o que está acarretando na falta de informações privilegiadas que conduzam os policiais aos locais de maior concentração criminal, além de não poder identificar os padrões que se manifestam nos crimes.

Nesse sentido, esse trabalho focou na utilização de técnicas de inteligência computacional para auxiliar o processo de análise de dados criminais da cidade de Mossoró. Assim, foram obtidos modelos capazes de identificar os locais de maior concentração criminal, ou seja, os *hot spots* criminais, como também os padrões que se repetem nos crimes ao longo do tempo com a obtenção dos reticulados conceituais.

Para a obtenção dos modelos com *hot spots* criminais foi utilizado a técnica de análise de agrupamento com o algoritmo *K-Means* capaz de agrupar locais de acordo com as similaridades que se repetem nesses locais.

Para a obtenção dos modelos com reticulados conceituais foi utilizado a técnica de análise de conceitos formais capaz de extrair padrões do conjunto de ocorrências.

Com a obtenção desses modelos, também foi proposto uma classificação do nível de periculosidade de cada bairro. Essa classificação foi feita por meio de cálculos que permitiram avaliar os bairros por meio de um *ranking* de periculosidade.

Os modelos obtidos receberam *feedback* positivo por parte de especialistas em criminalidade, especificamente, de policiais integrados ao CIOSP, Mossoró.

### 7.1 DIVULGAÇÃO DOS RESULTADOS

Um artigo com a descrição inicial da proposta foi publicado na Escola Potiguar de Computação e suas Aplicações Farias et al. (2013).



Um segundo trabalho, com uma descrição mais detalhada da proposta e resultados iniciais foi submetida para o 15<sup>th</sup> International Conference on Information Processing and Management of Uncertainty in Knowledge-Based Systems.

Está sob elaboração um artigo com a descrição completa da proposta e resultados dos experimentos adicionais para ser submetido ao congresso da NAFIPS, North American Information Processing Society.

## 7.2 TRABALHOS FUTUROS

Com o *feedback* recebido dos especialistas foi possível identificar várias possibilidades de melhorias e trabalhos futuros. Por exemplo, foi observado ao longo da evolução desse trabalho que a extração de padrões poderia abranger mais características, ou seja:

- Características sobre o crime: arma envolvida, tipo do local onde o crime se manifestou e quantidade de envolvidos.
- Características sobre os criminosos e as vítimas: idade, sexo, cor, profissão e nível de escolaridade.

Assim, pretende-se ampliar os experimentos incluindo outros atributos.

Os modelos gerados de *hot spots* criminais podem ser refinados, e também gerados semanalmente e até mesmo para dias específicos da semana. Esses experimentos também devem ser feitos.

Também pretende-se utilizar a lógica fuzzy na classificação do nível de periculosidade de cada bairro.

Na proposta desse trabalho, foi definido o objetivo de gerar modelos que possam ser facilmente aplicados outras bases de dados, ou seja, a outras cidades. Pretende-se trabalhar nesse sentido e ampliar a validação dos modelos com novas bases de dados.

## REFERÊNCIAS

- BARROS, L. A. **Dicionários eletrônicos Aurélio e Houaiss**: recursos informáticos de que dispõem, semelhanças e diferenças. [S.l.]: Annablume, 2005. Citado na página 20.
- BORDIN, M.; LIMA, R. de. Mapeamento do crime e análise criminal: A experiência do estado do paran . **Geografares**, n. 10, 2012. ISSN 2175-3709. Dispon vel em: <<http://www.periodicos.ufes.br/geografares/article/view/1666>>. Citado na p gina 33.
- BRAGA, L. P. V. **Introdu o a Minera o de Dados**. [S.l.]: E-papers Servi os Editoriais, 2005. Citado 2 vezes nas p ginas 23 e 25.
- CHANDRA, B.; GUPTA, M.; GUPTA, M. P. A multivariate time series clustering approach for crime trends prediction. In: **IEEE International Conference on Systems, Man and Cybernetics**. [S.l.: s.n.], 2008. p. 892–896. ISSN 1062-922X. Citado na p gina 31.
- CINTRA, M. E. **Genetic generation of fuzzy knowledge bases**: new perspectives. Tese (Doutorado) — University of Saulo, 2012. Citado 2 vezes nas p ginas 26 e 29.
- CINTRA, M. E. et al. The use of fuzzy decision trees for coffee rust warning in brazilian crop. In: **11th International Conference on Intelligent Systems Design and Applications**. [S.l.: s.n.], 2011. v. 1, p. 1347–1352. Citado 2 vezes nas p ginas 26 e 28.
- COSTA, L. R. **Metodologia e Arquitetura para Sistematiza o do Processo Investigat rio de An lise da Informa o Digital**. Disserta o (Mestrado) — Universidade de Bras lia, 2012. Citado 2 vezes nas p ginas 16 e 17.
- CRIMINAL STICA, I. N. de. **Relat rio Estat stico das Atividade do Sistema Nacional de Criminal stica**. [S.l.], 2012. Citado 2 vezes nas p ginas 17 e 18.
- CRUZ, F. V. **An lise da Criminalidade em Palmas-TO: Uma Abordagem Espacial da Viol ncia Urbana**. Disserta o (Mestrado) — Universidade Federal do Tocantins, 2010. Citado na p gina 32.
- ECK, J. E. et al. **Mapping Crime**: understanding Hot Spots. [S.l.]: National Institute of Justice, 2005. Citado 2 vezes nas p ginas 19 e 20.
- FARIAS, A. M. G. de et al. Detec o de hot spot criminal com aplica o de an lise de agrupamento. In: **Escola Potiguar de Computa o e suas Aplica es**. [S.l.: s.n.], 2013. Citado na p gina 62.
- F RUM BRASILEIRO DE SEGURAN A P BLICA. **Anu rio Brasileiro de Seguran a P blica**. 7. ed. S o Paulo, 2013. Citado na p gina 11.

FREI, F. **Introdução a análise de agrupamentos: teoria e prática.** [S.l.]: UNESP, 2006. Citado na página 22.

GANTER, B. **Formal Concept Analysis: Algorithmic Aspects.** [S.l.], 2002. 52 pages. Disponível em: <<http://www.math.tu-dresden.de/~ganter/cl03/cl02.pdf>>. Citado na página 30.

GAY, W. G.; BEALL, T. M.; BOWERS, R. A. **Integrated Criminal Apprehension Program.** [S.l.]: Science Center, 1982. Citado 2 vezes nas páginas 14 e 15.

GOOGLE. **GOOGLE EARTH MAPS.** 2014. Disponível em: <<https://developers.google.com/earth/documentation/examples?hl=pt-BR>>. Citado na página 41.

HALLN, M. et al. *The WEKA Data mining software: an update.* SIGKDD Explorations, 2009. Disponível em: <<http://www.cs.waikato.ac.nz/ml/weka/>>. Citado na página 37.

KESTER, Q.-A. Criminal geographical profiling: Using fca for visualization and analysis of crime data. **International Journal of Research in Engineering & Advanced Technology (IJREAT)**, v. 1.5, p. 1–5, 2013. Citado na página 33.

KESTER, Q.-A. Visualization and analysis of geographical crime patterns using formal concept analysis. **International Journal of Science, Engineering and Technology Research**, v. 2.1, p. 220–225, 2013. Citado na página 34.

KRAJCA, P.; OTRATA, J.; VYCHODIL, V. Parallel algorithm for computing fixpoints of galois connections. **Annals of Mathematics and Artificial Intelligence**, Kluwer Academic Publishers, Hingham, MA, USA, v. 59, p. 257–272, June 2010. ISSN 1012-2443. Disponível em: <<http://dx.doi.org/10.1007/s10472-010-9199-5>>. Citado na página 30.

LINDEN, R. Clustering techniques. **Revista de Sistemas de Informação da FSMA**, v. 4, p. 18–36, 2009. Citado na página 26.

MAJIDIAN, A.; MARTIN, T.; CINTRA, M. E. Fuzzy formal concept analysis and algorithm. In: **Proceedings of the 11th Annual Workshop on Computational Intelligence - UKCI.** [S.l.: s.n.], 2011. p. 1–7. Citado na página 26.

MALHOTA, N. K. **Marketing research: an applied orientation.** [S.l.]: Pearson Education, 2004. Citado na página 24.

MALTZ, M. D.; GORDON, A. C.; FRIEDMAN, W. **Mapping crime in its community setting: event geography analysis.** [S.l.]: Springer-Verlag, 2007. Citado na página 21.

MESA DA CÂMARA DOS DEPUTADOS. **Estatuto do desarmamento.** 5. ed. Brasília, 2013. Citado na página 12.

MIRANDA, A. P. M. de et al. **Análise criminal e o planejamento operacional**. [S.l.], 2008. Citado 2 vezes nas páginas 19 e 44.

MORAES, G.; CAPOBIAANCO, R. J. **Curso de direito penal**. [S.l.]: Forense, 2011. Citado na página 20.

MUSDHOLIFAH, A.; HASHIM, S.; WASITO, I. Knn-kernel based clustering for spatio-temporal database. In: **International Conference on Computer and Communication Engineering (ICCCE)**. [S.l.: s.n.], 2010. p. 1–6. Citado na página 32.

OSGOOD, D. W. Poisson-based regression analysis of aggregate crime rates. **Journal of Quantitative Criminology**, v. 16, 2000. Citado na página 31.

PEIXOTO, B. T. **Curso análise criminal: módulo 1**. [S.l.], 2008. Citado 2 vezes nas páginas 14 e 20.

POELMANS, J. et al. Concept discovery innovations in law enforcement: A perspective. In: **Intelligent Networking and Collaborative Systems (INCOS), 2010 2nd International Conference on**. [S.l.: s.n.], 2010. p. 473–478. Citado na página 31.

TILLEY, T. Tool support for fca. In: **Concept Lattices**. [S.l.]: Springer, 2004. p. 104–111. Citado na página 42.

TURBAN, E. et al. **Business intelligence: a managerial approach**. [S.l.]: Bookman, 2008. Citado na página 22.

WILLE, R. Restructuring lattice theory: An approach based on hierarchies of concepts. In: **Proceedings of the 7th International Conference on Formal Concept Analysis**. Berlin, Heidelberg: Springer-Verlag, 2009. (ICFCA '09). Citado na página 27.

WINCK, A. T. **3D-Tri: Um Algoritmo de Indução de Árvore de Regressão para Propriedades Tridimensionais - um estudo sobre dados de docagem molecular considerando a Flexibilidade do receptor**. Tese (Doutorado) — Pontifícia Universidade Católica do Rio Grande do Sul, 2012. Citado na página 26.

YEVTUSHENKO, S. **Conexp software**. 2013. Disponível em: <<http://www.sf.net/projects/conexp>>. Citado na página 37.

YU, P.-H.; LAY, J.-G. Exploring non-stationarity of local mechanism of crime events with spatial-temporal weighted regression. In: **IEEE International Conference on Spatial Data Mining and Geographical Knowledge Services (ICSDM)**. [S.l.: s.n.], 2011. p. 7–12. Citado na página 32.

ZHANG, X. et al. Detecting and mapping crime hot spots based on improved attribute oriented induce clustering. In: **Geoinformatics, 2010 18th International Conference on**. [S.l.: s.n.], 2010. p. 1–5. Citado 2 vezes nas páginas 19.

## ANEXO A – Mapas com *Hot spots* criminais para todos os períodos, de 8 a 20 centros

Os mapas com *Hot spots* criminais apresentados no Capítulo 6 são os gerados com 12 centros. Os demais mapas não foram incluídos nesse capítulo para facilitar a interpretação dos mesmos.

Todos os demais mapas, definidos com 8 a 20 centros, são apresentados a seguir.

Figura 23 – Mapa com 8 *hot spots* criminais.



**MADRUGADA**



**MANHÃ**



**TARDE**



**NOITE**


Figura 24 – Mapa com 9 *hot spots* criminais.




**MADRUGADA**



**MANHÃ**

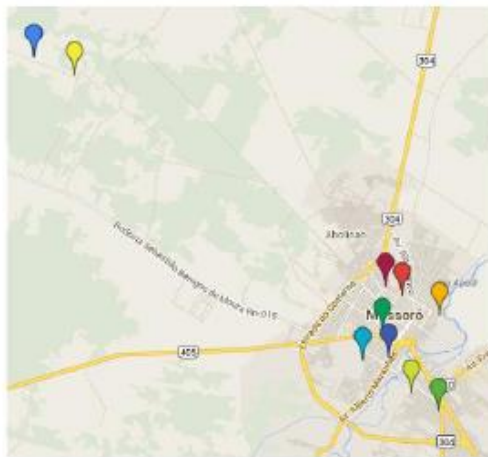


**TARDE**

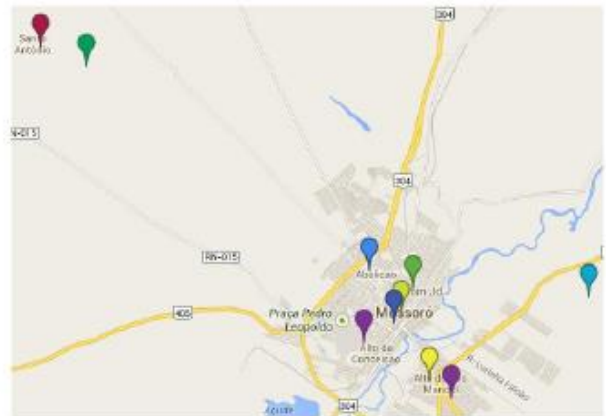


**NOITE**


Figura 25 – Mapa com 10 *hot spots* criminais.



**MADRUGADA**



**MANHÃ**

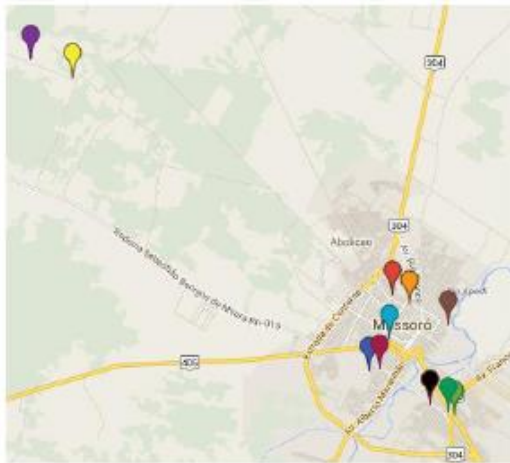


**TARDE**

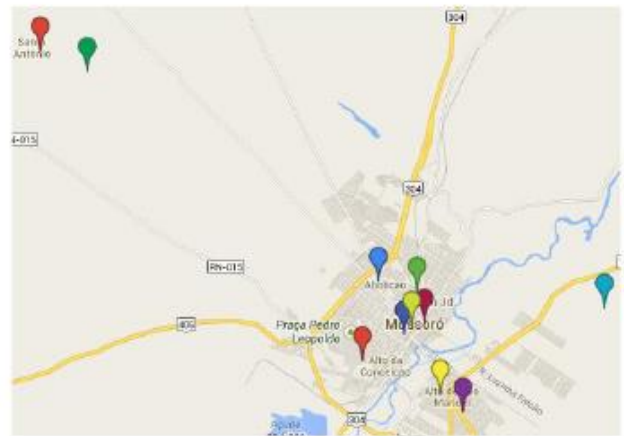


**NOITE**

Figura 26 – Mapa com 11 hot spots criminais.



**MADRUGADA**



**MANHÃ**



**TARDE**



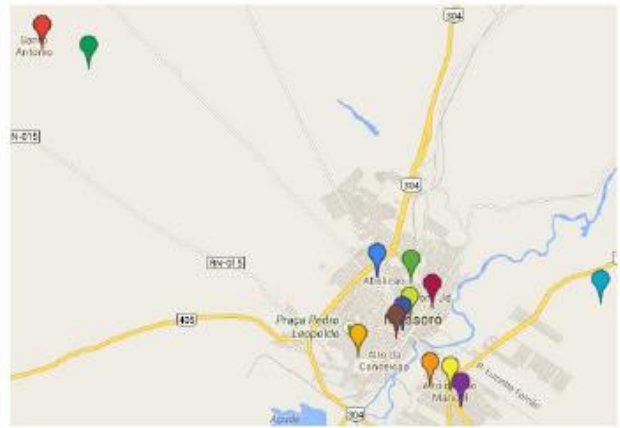
**NOITE**




Figura 27 – Mapa com 13 hot spots criminais.



**MADRUGADA**



**MANHÃ**



**TARDE**

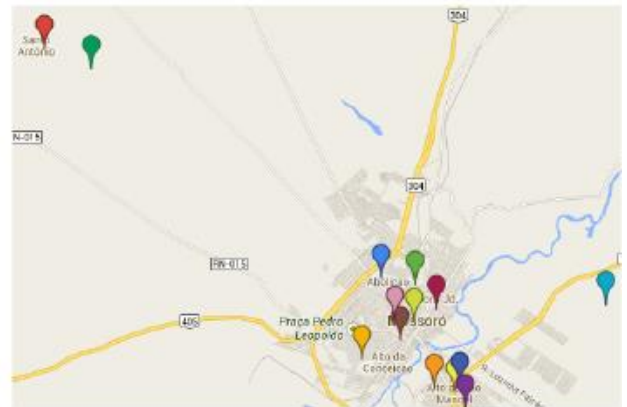


**NOITE**


Figura 28 – Mapa com 14 hot spots criminais.




**MADRUGADA**



**MANHÃ**

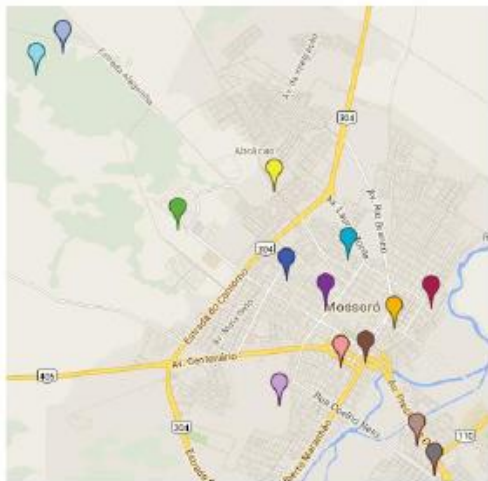


**TARDE**

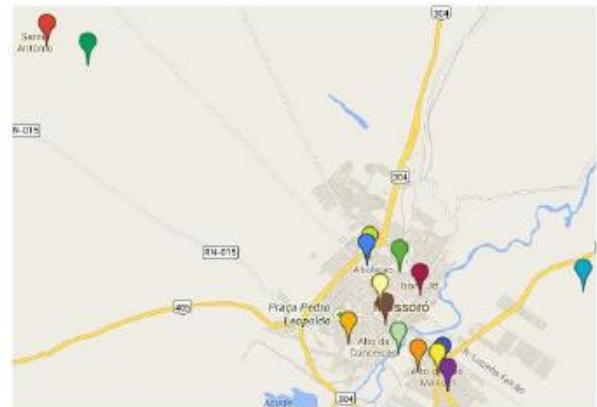


**NOITE**


Figura 29 – Mapa com 15 *hot spots* criminais.



**MADRUGADA**



**MANHÃ**




**TARDE**



**NOITE**


Figura 30 – Mapa com 16 hot spots criminais.



**MADRUGADA**



**MANHÃ**




**TARDE**



**NOITE**


Figura 31 – Mapa com 17 *hot spots* criminais.



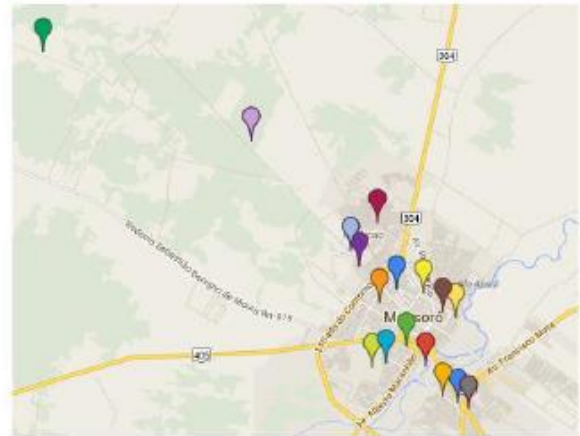
**MADRUGADA**



**MANHÃ**

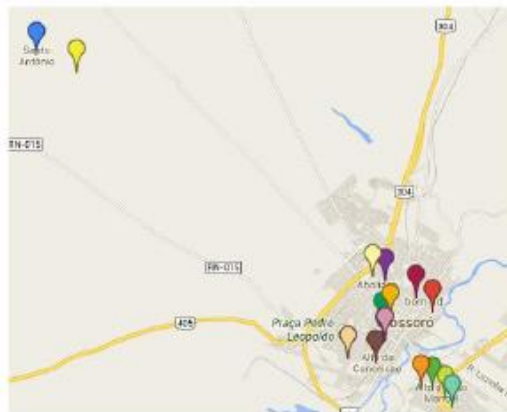


**TARDE**



**NOITE**


Figura 32 – Mapa com 18 *hot spots* criminais.




**MADRUGADA**



**MANHÃ**



**TARDE**



**NOITE**


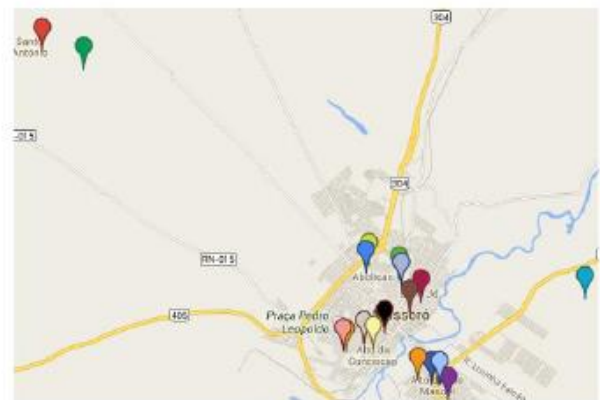


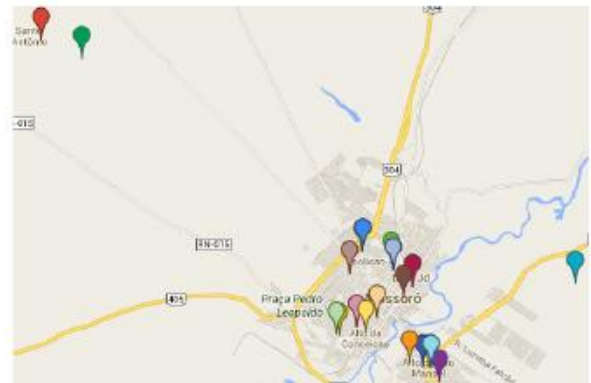
Figura 33 – Mapa com 19 *hot spots* criminais.**MADRUGADA****MANHÃ****TARDE****NOITE**

Figura 34 – Mapa com 20 hot spots criminais.




**MADRUGADA**



**MANHÃ**



**TARDE**



**NOITE**