

UNIVERSIDADE FEDERAL DE SANTA CATARINA
DEPARTAMENTO DE INFORMÁTICA E ESTATÍSTICA

Eduardo Machado Carboni

ANÁLISE DE COMPORTAMENTO DE MOTORISTAS
ATRAVÉS DE TRAJETÓRIAS DE OBJETOS MÓVEIS

Florianópolis
2014

Eduardo Machado Carboni

ANÁLISE DE COMPORTAMENTO DE MOTORISTAS
ATRAVÉS DE TRAJETÓRIAS DE OBJETOS MÓVEIS

Dissertação submetida ao Programa
Pós-Graduação em Ciência da
Computação para a obtenção do grau de
Mestre em Ciência da Computação na
Universidade Federal de Santa Catarina.
Orientadora: Prof.^a Vania Bogorny, Dr.^a

Florianópolis
2014

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Carboni, Eduardo Machado

ANÁLISE DE COMPORTAMENTO DE MOTORISTAS ATRAVÉS DE
TRAJETÓRIAS DE OBJETOS MÓVEIS / Eduardo Machado Carboni ;
orientadora, Vania Bogorny - Florianópolis, SC, 2014.
76 p.

Dissertação (mestrado) - Universidade Federal de Santa
Catarina, Centro Tecnológico. Programa de Pós-Graduação em
Ciência da Computação.

Inclui referências

1. Ciência da Computação. 2. Trajetórias de Veículos. 3.
Padrões de Comportamento e Anomalias. 4. Classificação de
Motoristas. 5. Locais Problemáticos nas Vias. I. Bogorny,
Vania. II. Universidade Federal de Santa Catarina.
Programa de Pós-Graduação em Ciência da Computação. III.
Título.

Eduardo Machado Carboni

ANÁLISE DE COMPORTAMENTO DE MOTORISTAS ATRAVÉS DE TRAJETÓRIAS DE OBJETOS MÓVEIS

Esta Dissertação foi julgada adequada para obtenção do Título de “Mestre em Ciência da Computação”, e aprovada em sua forma final pelo Programa de Pós-Graduação em Ciência da Computação.

Florianópolis, 01 de outubro de 2014.

Prof. Ronaldo dos Santos Mello, Dr.
Coordenador do Curso

Prof.^a Vania Bogorny, Dr.^a
Orientadora

Banca Examinadora:

Prof.^a Patrícia Della Mea Plentz, Dr.^a
Presidente
Universidade Federal de Santa Catarina

Prof. Fernando José Braz, Dr.
Instituto Federal Catarinense

Prof. Renato Fileto, Dr.
Universidade Federal de Santa Catarina

Prof. Ronaldo dos Santos Mello, Dr.
Universidade Federal de Santa Catarina

Dedico este trabalho à minha família, que sempre esteve comigo em todos os momentos de minha vida para me orientar, aconselhar e apoiar.

AGRADECIMENTOS

Agradecimento especial para minha orientadora, Vania Bogorny, que tornou tudo isso possível. Sempre disposta a me guiar pelo caminho certo, enquanto me deixava caminhar com meus próprios pés, seus conselhos e críticas fizeram deste trabalho o que ele é hoje. Obrigado pela paciência, ensinamentos e por me orientar neste longo mestrado que se estendeu por mais tempo que o planejado.

Meus agradecimentos aos meus pais, Altair Carboni e Maria Gorete Machado Carboni, que confiaram e me apoiaram durante todos estes anos que estive estudando distante de suas companhias. O que eu sou hoje devo tudo a eles.

Também agradeço aos meus irmãos Julian Machado Carboni e Fernando Machado Carboni que sempre me apoiaram quando precisei e sempre me serviram como exemplos a serem seguidos nos caminhos que segui.

Agradeço a minha namorada Dyeovana Ramos, que no final desta batalha vem me incentivando a continuar com força e vontade para chegar honradamente ao resultado final com qualidade.

Palavras não podem expressar meus agradecimentos a todos os meus amigos espalhados pelos caminhos que segui. Meus amigos da faculdade que tenho contato mais próximo como Brian Henkels, Tiago Bortoli, Samuel Steckert e Rafael Bianco foram essenciais nesse caminho. Meus amigos de Orleans que sempre estão prontos para qualquer desafio como Leandro Benedet e Leonardo Benedet. Agradeço também aos meus professores e amigos João Cândido Dovicchi, João Bosco Mangueira Sobral e Luis Otavio Alvares, que sempre estiveram prontos para tirar dúvidas e foram como co-orientadores nas várias conversas que tivemos, onde compartilharam comigo suas experiências na área acadêmica. Muito importante ao longo desse mestrado também foram meus amigos e colegas de trabalho na Wedo Technologies que me deram suporte e sempre apoiaram a minha conclusão do mestrado, como Leandro Lameirão, Jessé Jair Santos, Fernando Moretti, Pedro Grandi e André Petrosky. Ainda, agradeço aos colegas e amigos de pesquisa que compartilharam a mesma orientadora e me ajudaram quando precisei, como Fernando de Lucca Siqueira e Artur Ribeiro de Aquino. Ao falar dos colegas de pesquisa, não poderia deixar de mencionar a Katiana que sempre esteve na secretaria do programa esclarecendo inúmeras dúvidas e ajudando quando estivesse ao seu alcance.

Gostaria de agradecer a Universidade Federal de Santa Catarina, especialmente ao Departamento de Informática e Estatística e ao Programa de Pós-Graduação em Ciência da Computação, por terem me proporcionado este projeto durante estes anos. Também agradeço ao Grupo de Banco de Dados da UFSC, em especial a banca do projeto pertencente ao grupo e composta por Renato Fileto e Ronaldo dos Santos Mello, que me ajudaram fazendo críticas e sugestões ao trabalho em todos os entregáveis do projeto. Agradeço também aos professores Fernando Braz por fazer parte da banca deste trabalho e Patrícia Plentz por aceitar ser a presidente da defesa.

Agradeço ao CNPQ e ao projeto SEEK EU por apoiarem parcialmente minha pesquisa de mestrado.

*“Quem não é sonhador, não tem chance de
crescer um dia.
Quem é sonhador tem.
Quem é sonhador, tem chance de crescer um dia
Quem não é não tem.
...
Tudo que você quiser pode estar ao seu alcance e
você não vê.
Às vezes é preciso perder o juízo para vencer.
...”*

(Inkaktus Prole – Sonhador)

RESUMO

Todos os dias o número de veículos circulando pelas estradas é maior e, se estiverem equipados com dispositivos móveis tais como GPS, é gerado um novo tipo de dado chamado de trajetória. Vários estudos buscam descobrir padrões em trajetórias, mas poucos têm focado na análise do comportamento de motoristas. Através das trajetórias geradas pelos veículos é possível inferir bons e maus condutores e encontrar locais problemáticos ao longo das vias caso existam padrões de comportamento bem definidos. Esta dissertação propõe um método para análise de comportamento de motoristas através das suas trajetórias, com base em características como acelerações, desacelerações e mudanças bruscas de direção, excesso de velocidade, comportamento de costura, limites de velocidade das vias, bem como locais que possam ser causadores de um movimento anômalo, tal qual um semáforo. Trabalhos na literatura não classificam motoristas utilizando dados de GPS e não detectam ou analisam movimentos anômalos com justificativas para as anomalias. O método é avaliado através de experimentos com dados reais que mostram ser possível classificar motoristas com base em suas trajetórias.

Palavras-chave: Trajetórias de Veículos. Padrões de Comportamento. Comportamento Anômalo. Classificação de Motoristas. Locais Problemáticos nas Vias.

ABSTRACT

Every day the number of vehicles driving on the roads is increasing, and if equipped with mobile devices such as GPS, a new data type called trajectory is generated. Several studies seek to discover patterns in trajectories, but only a few have focused on analyzing the behavior of drivers. Through the trajectories generated by the vehicles it is possible to infer good and bad drivers, as well as problematic places along the roads if there are well-defined behavior patterns. This thesis proposes a method for analyzing the behavior of drivers over their trajectories, based on characteristics such as acceleration, deceleration and abrupt changes of direction, speed, behavior of lane cutting and places that may be causing an anomalous movement, like a traffic light. Existing works in the literature do not classify drivers using GPS data considering repetitive anomalous movement or justifications of anomalies. The proposed method is evaluated through experiments with real data showing the possibility to classify drivers based on their trajectories.

Keywords: Trajectories of Vehicles. Patterns of Behavior. Anomalous Behavior. Classification of Drivers. Problematic Places at Roads.

LISTA DE FIGURAS

Figura 1. (a) Formato de dados de trajetórias, (b) Representação de uma trajetória num espaço 3D e (c) Várias trajetórias num espaço 3D. [34].....	28
Figura 2. Trajetória com aceleração brusca e desaceleração brusca	41
Figura 3. Exemplo de troca de faixa	44
Figura 4. Mudança de Faixa, Ultrapassagem e Costura	47
Figura 4. Troca de Faixa, Ultrapassagem e Costura	45
Figura 5. Fluxo do Algoritmo	48
Figura 6. Pontos de trajetória (Velocidade x Tempo) com falha de coleta	49
Figura 7. Sequência de pontos de trajetória (Velocidade x Tempo)	50
Figura 8. Raio da Curva.....	51
Figura 9. Exemplos de feições de interesse previamente conhecidas	58
Figura 10. Resultados para três diferentes conjuntos de parâmetros.....	61
Figura 11. Trajetória Muito Perigosa e Trajetória Perigosa.....	62
Figura 12. Detalhes de Locais Problemáticos	63
Figura 13. Resultados para três diferentes conjuntos de parâmetros para trajetórias de Ônibus	65
Figura 14. Trajetórias de Ônibus Conjunto 1.....	65
Figura 15. Locais Problemáticos Ônibus Conjunto 1	66
Figura 16. Exemplo de Locais Problemáticos encontrados com trajetórias de Ônibus.....	67
Figura 17. Trajetórias de Ônibus Conjunto 2.....	68

LISTA DE TABELAS

Tabela 1. Comparação do Estado da Arte.....	38
Tabela 2. Resultados para 5 conjuntos de parâmetros nos experimentos.....	59
Tabela 3. Resultados para 3 conjuntos de parâmetros nos experimentos de trajetórias de ônibus	64
Tabela 4. Classificação dos Motoristas para Trajetórias de Ônibus.....	69

LISTA DE ABREVIATURAS E SIGLAS

ANVISA	Agência Nacional de Vigilância Sanitária
GPS	Global Positioning System
WHO	World Health Organization
UFSC	Universidade Federal de Santa Catarina
INE	Departamento de Informática e Estatística
Costura frequentemente	Comportamento de motoristas que trocam de faixa
Java	Linguagem de programação orientada a objetos
IDE	Ambiente integrado para desenvolvimento de software
Software	Sequência de instruções executadas na manipulação de dados/informações
NetBeans	Um ambiente integrado para desenvolvimento de software utilizando Java
Postgres relacional	Sistema gerenciador de banco de dados objeto
GIS	Sistema de Informação Geográfica
Postgis	Extensão espacial construída sobre o Postgres
Quantum-GIS	Software para análise espacial.
CONTRAN	Conselho Nacional de Transito
CTB	Código de Trânsito Brasileiro
IEEE	Institute of Electrical and Electronics Engineers
IEEEIS	Intelligent Systems IEEE

SUMÁRIO

SUMÁRIO.....	25
1 INTRODUÇÃO E MOTIVAÇÃO	27
1.1 DEFINIÇÃO DO PROBLEMA E JUSTIFICATIVA.....	29
1.2 OBJETIVOS.....	30
1.3 METODOLOGIA E ESTRUTURA DA DISSERTAÇÃO.....	30
2 ESTADO DA ARTE	33
3 O MÉTODO PROPOSTO	39
3.1 DEFINIÇÕES BÁSICAS	39
3.2 DEFINIÇÕES PRINCIPAIS.....	40
3.3 ANÁLISE E CLASSIFICAÇÃO DOS MOTORISTAS	46
3.4 O ALGORITMO PROPOSTO	47
4 EXPERIMENTOS	57
4.1 ANÁLISE DE TRAJETÓRIAS DE VEÍCULOS DE PASSEIO	57
4.2 ANÁLISE DE TRAJETÓRIAS DE ONIBUS EM SC.....	63
4.2.1 Primeira Análise de Trajetórias de Ônibus	63
4.2.2 Segunda Análise de Trajetórias de Ônibus	67
5 CONCLUSÃO E TRABALHOS FUTUROS	71
REFERÊNCIAS	73

1 INTRODUÇÃO E MOTIVAÇÃO

Todos os dias várias pessoas são vítimas de acidentes de trânsito, que estão diretamente relacionados ao comportamento dos motoristas. Segundo a Organização Mundial de Saúde (WHO), o número total de mortes no trânsito em todo o mundo é de cerca de 1,24 milhões de pessoas por ano [30]. Tem-se conhecimento de que as principais causas de acidentes estão relacionadas ao excesso de velocidade, motoristas embriagados, mudanças entre faixas de trânsito em momentos impróprios, corridas de rua, entre outros [31]. O comportamento dos motoristas pode afetar não só o tráfego, mas os pedestres que cruzam a rua, os passageiros em um ônibus ou táxi, e até mesmo gerar danos no transporte de produtos delicados, como frutas e legumes.

Não existem muitas formas de captar dados para analisar o comportamento dos motoristas. Contudo, pode-se utilizar dispositivos que se movem com os motoristas, como GPS, sensores instalados nos veículos, cameras que capturam vídeos onde o motorista trafega, ou ainda, monitores humanos que acompanham os motoristas e registram suas atitudes ao dirigir.

Enquanto alguns equipamentos possuem altos valores ou são de difícil uso, os dispositivos móveis vêm ficando cada vez mais populares e reduzindo seus valores de mercado. Os fabricantes de aparelhos celulares estão comercializando aparelhos equipados com GPS e montadoras já fabricam veículos com sistemas de rastreamento por satélite. Mesmo que não saibamos que o georreferenciamento está de alguma forma sendo usado, grandes volumes de dados estão sendo gerados por estes dispositivos, representando “*as pegadas*” dos objetos ou o caminho que os mesmos percorreram. Dados que representam o caminho percorrido pelo objeto são representados na forma de *tid*, x , y e t , onde *tid* é o identificador da trajetória do objeto, x e y representam as coordenadas geográficas e t é o tempo no instante da coleta do ponto. O conjunto destes pontos gera um tipo de dado espaço-temporal chamado de *trajetória do objeto móvel*. A figura 1 ilustra um exemplo de trajetória. É possível visualizar na figura 1 como as trajetórias são representadas em um banco de dados (a), visualizar a representação de um conjunto de pontos localizados no espaço e no tempo, caracterizando o movimento de um objeto móvel (b) e um conjunto de trajetórias no espaço (c).

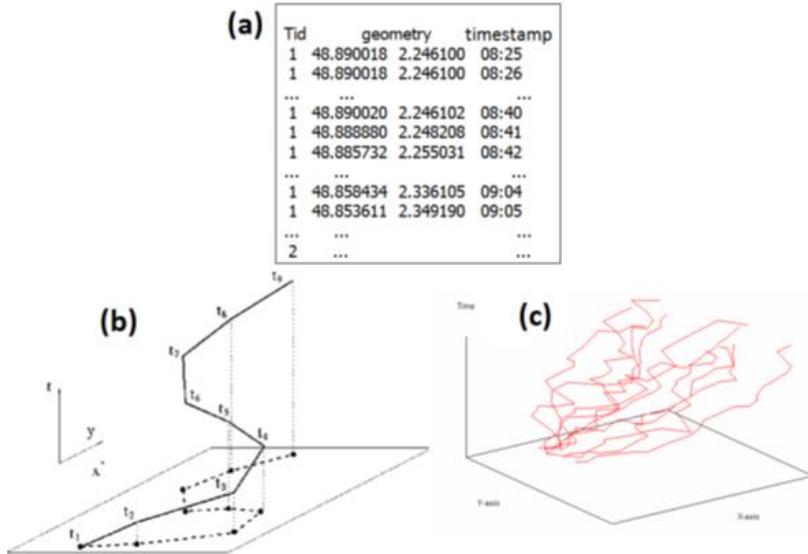


Figura 1. (a) Formato de dados de trajetórias, (b) Representação de uma trajetória num espaço 3D e (c) Várias trajetórias num espaço 3D. [34]

É possível encontrar de maneira detalhada alguns conceitos de trajetórias de objetos móveis, a maneira de armazenamento desse tipo de dado e formas de análise desses dados na obra apresentada por Braz e Bogorny [44].

A coleta dos dados pelos dispositivos móveis é realizada em intervalos de tempo definidos. O intervalo de tempo pode ser em horas, minutos, ou até segundos. Para a análise do comportamento de um motorista é preciso que o intervalo seja curto, pois as ações são realizadas em questão de poucos segundos. Por esse motivo, o volume de dados gerado pelos dispositivos móveis pode ser muito grande, tornando difícil a análise visual dos dados gerados, conforme demonstrado na figura 1 (c).

Analisar o comportamento de um motorista através de suas trajetórias pode ser muito útil em diversas aplicações. No transporte de alimentos, segundo a ANVISA, 30% de frutas e verduras são perdidas pelo modo como são transportadas. Vários fatores podem afetar o transporte, como locais sem sinalização onde existam semáforos, lombadas, escolas, obras, vias em más condições, etc. Nestas situações, um motorista possivelmente irá frear bruscamente ou realizar uma

manobra de mudança brusca de direção, objetivando desviar do local inesperado.

1.1 DEFINIÇÃO DO PROBLEMA E JUSTIFICATIVA

Atualmente existem diversos estudos que exploram dados de trajetórias. Alguns trabalhos procuram por regiões importantes ao longo das trajetórias como, por exemplo, Alvares [14], Palma [15] e Rocha [25]. Outros tentam classificar as trajetórias em tipos específicos, como trajetórias de turistas ou trajetórias de viajantes [16], trajetórias que desviam de determinados locais ou objetos [24] ou perseguição entre trajetórias [26]. Também existem estudos que buscam padrões de comportamento de grupos de trajetórias [20], desvios de rota [19], classificação de grupos de trajetórias [21] e [18], entre outros.

Vários trabalhos, como Pentland [2], Rigolli [3], Sathyanarayana [4], Imamura [5], Inata [6], Quintero [7], Gindele [8] e Quintero [13] têm sido propostos para a análise do comportamento de motoristas em sistemas de simulação de veículos, utilizando dados obtidos de câmeras, sensores e outros dispositivos, mas não utilizando trajetórias reais de veículos. Em Pentland [2], Sathyanarayana [4] e Gindele [8], por exemplo, sensores e simuladores são usados para reconhecer os movimentos dos motoristas em ultrapassagens, mudanças de faixa e acelerações. Em Rigolli [3], Imamura [5] e Quintero [7] os motoristas são classificados em diferentes níveis de periculosidade, considerando as características do próprio veículo em relação à distância e a velocidade dos veículos nas proximidades. Um trabalho mais recente de Quintero [13] classifica os motoristas usando o excesso de velocidade, saídas da estrada, mudanças bruscas no volante, no pedal acelerador e no pedal de freio.

Apenas alguns trabalhos na literatura como Liao[9] e Zhang[10] utilizam trajetórias de objetos móveis, ou seja, as trajetórias de movimentos reais dos motoristas. No trabalho de Liao [9], o objetivo é encontrar motoristas de táxis imprudentes com base na velocidade do táxi e a região onde o táxi passa. Já no trabalho de Zhang [10] o foco é em trajetórias anormais de táxis que desviam da rota padrão de origem e destino. Estudos existentes que consideram trajetórias, basicamente procuram padrões gerais ou situações atípicas em trajetórias (*outliers*), como Fontes [42] e Aquino [43], e não analisam o comportamento dos motoristas e nem os classificam em níveis de periculosidade.

Muitos fatores externos podem também afetar o comportamento dos motoristas e forçar movimentos anômalos, mas não necessariamente

pela irresponsabilidade do motorista. Lugares sem sinalização onde existem lombadas, semáforos, escolas, buracos, animais cruzando a estrada, ou fiscalizações policiais, podem levar um motorista a realizar movimentos bruscos como, mudanças de direção ou desacelerações bruscas, mas com a intenção de evitar uma situação inesperada. A descoberta de tais movimentos pode ser útil também para os departamentos de gestão de tráfego para melhorar as condições de condução e sinalizações. A descoberta de motoristas que possuem comportamento anômalo pode ajudar as empresas a aconselhar os motoristas sobre seu comportamento ou para não mantê-los em tais empregos. Ainda, podem ajudar a prevenir os acidentes e reduzir o desperdício no abastecimento de alimentos.

Este trabalho se concentra em trajetórias reais dos motoristas, propondo um algoritmo para identificar comportamentos anômalos baseado em movimentos bruscos de trajetórias, descobrir as razões para os movimentos bruscos e classificar motoristas em níveis de periculosidade. Ainda, considerando a utilidade de descobrir locais “*problemáticos*” nas vias, onde repetidamente acontecem movimentos bruscos, é retornada além da classificação dos motoristas, a listagem de locais onde ocorreram mais anomalias.

1.2 OBJETIVOS

O objetivo principal deste trabalho é analisar as trajetórias dos motoristas, buscando detectar anomalias e classificar os motoristas em níveis de periculosidade. Para a obtenção do objetivo principal, são propostos os seguintes objetivos específicos:

- 1) Definir formalmente os tipos de anomalias consideradas;
- 2) Definir, para esta dissertação, diferentes níveis de periculosidade;
- 3) Definir um algoritmo que seja capaz de:
 - a. Encontrar anomalias e classificar os motoristas em níveis de periculosidade;
 - b. Detectar possíveis locais problemáticos nas vias.

1.3 METODOLOGIA E ESTRUTURA DA DISSERTAÇÃO

A metodologia desta dissertação compreende os seguintes passos:

- 1) Levantamento bibliográfico sobre trabalhos relacionados na área de análise de motoristas;
- 2) Definir formalmente as anomalias em trajetórias e níveis de periculosidade de motoristas. Com o estudo da literatura e o conhecimento de especialistas são definidos conceitos formais de movimentos anômalos. Com a combinação dos movimentos anômalos são definidos os diferentes níveis de periculosidade;
- 3) Definir e implementar um algoritmo capaz de encontrar anomalias em trajetórias, descobrir repetições de anomalias em locais diferentes de um mesmo motorista, repetições de anomalias em um mesmo local de diferentes motoristas, comparar as trajetórias com limites máximos de velocidade, classificar os motoristas em níveis de periculosidade e encontrar locais “problemáticos” nas estradas;
- 4) Coletar dados de trajetórias para a realização de experimentos: a coleta de dados se fará através de aparelhos de GPSs reais alocados em veículos de passeio e transporte coletivo, com os pontos captados em intervalos de 1 segundo;
- 5) Realizar experimentos com dados reais de trajetórias, gerando a classificação dos motoristas;
- 6) Analisar e discutir os parâmetros utilizados.
- 7) Escrita de um artigo científico relacionado ao trabalho proposto e publicação do mesmo em evento com *Qualis-CC CAPES*, nos estratos A ou B;
- 8) Escrever a Dissertação.

O restante da dissertação está organizada da seguinte maneira: o Capítulo 2 apresenta o estado da arte. O Capítulo 3 apresenta o método proposto. O Capítulo 4 apresenta os experimentos e o Capítulo 5 descreve a conclusão e os trabalhos futuros.

2 ESTADO DA ARTE

Vários trabalhos na literatura analisam o comportamento de motoristas, porém utilizando dados gerados por simuladores e sensores, mas não trajetórias geradas por aparelhos de GPS. Pentland [2], por exemplo, propôs um modelo para análise do comportamento de motoristas a fim de prever as sequências de ações em poucos segundos. Em uma simulação computadorizada, utilizando dados de um carro com sensores para controlar o ângulo de mudança da direção no volante, velocidade e aceleração, são reconhecidas com antecedência as futuras ações de um motorista, mas não para encontrar anomalias nos movimentos. Gindele [8] desenvolveu um modelo que estima o comportamento dos motoristas utilizando sensores nas rodas. Comparando as ações encontradas pelos sensores das rodas e em sensores baseados na distância dos veículos próximos são definidos os seguintes comportamentos: *free_ride* (quando não há nenhum veículo a frente), *following* (quando há um veículo à frente na mesma faixa), *acceleration_phase* (quando o veículo acelera para tornar-se rápido o suficiente para ultrapassar o veículo da frente), *sheer_out* (quando o veículo continua acelerando e muda de faixa para ultrapassar), *overtake* (quando o veículo se mantém ultrapassando até que esteja longe o suficiente do outro veículo para voltar à sua faixa inicial) e *sheer_in* (quando o veículo se move de volta para a faixa inicial e volta aos estados *free_ride* ou *following*). O foco deste trabalho é na análise de movimentos efetuados pelos motoristas em relação aos outros veículos nas proximidades, e não na descoberta de movimentos bruscos ou classificação dos motoristas em níveis de periculosidade. Sathyanarayana [4] utiliza em sua análise a velocidade, o ângulo de mudança de direção do volante e a utilização dos pedais de freio e acelerador para encontrar diferentes manobras dos motoristas. Com a sequência de movimentos encontrados pelos sensores são descobertas três manobras diferentes (curva à esquerda, curva à direita e mudança de faixa). Neste trabalho, o único objetivo é encontrar essas três diferentes manobras.

No conjunto de obras que analisam o comportamento de motoristas utilizando simuladores e sensores em vez de trajetórias reais, alguns deles classificam motoristas. Imamura [5] classifica os motoristas em normais e anormais, utilizando uma correlação entre o funcionamento do volante e a velocidade do veículo em um simulador. No simulador, os motoristas que alteram muito a direção do volante em velocidades altas são considerados anormais. Inata [6] propôs um

método para encontrar o comportamento anômalo de motoristas e classificá-los em bons ou maus condutores com base na velocidade, distância de veículos próximos, e aceleração e desaceleração medida por sensores nos pedais. Ele utiliza a velocidade dos veículos e o tempo de resposta dos motoristas para acelerar e desacelerar quando estão próximos à outros veículos. Por exemplo, um motorista que está em alta velocidade e demora para desacelerar o veículo ao encontrar outro a frente é considerado um mau motorista, pois se diminuísse a velocidade antecipadamente ele evitaria possíveis colisões. Rigolli [3] classifica os motoristas em agressivos, seguros e cautelosos. A análise é realizada para cada veículo em relação aos veículos nas proximidades, considerando-se a velocidade de um veículo em relação à velocidade e a distância dos veículos próximos. A velocidade normal de um veículo deve ser semelhante à velocidade dos veículos próximos. Se os veículos das proximidades possuem velocidade em torno de 100 km/h e um veículo está em alta velocidade (e.g. 150 km/h), o mais rápido é classificado como agressivo. Em resumo, Rigolli define o comportamento dos motoristas em relação aos outros motoristas nas proximidades, considerando a distância e a velocidade, enquanto neste trabalho são considerados os movimentos bruscos nas trajetórias individuais de cada condutor.

Dentre os trabalhos desenvolvidos em simuladores, o trabalho de Quintero [7] é o mais próximo da nossa abordagem. O objetivo é descobrir falhas de motoristas como o excesso de velocidade, movimentações fora da estrada, oscilações bruscas no volante e as mudanças bruscas nos pedais de acelerador e freio, gerando um percentual de erros. Este trabalho é estendido em Quintero [13], onde o percentual de falhas é usado para classificar os motoristas nos seguintes níveis de periculosidade: moderados e agressivos.

Os trabalhos apresentados anteriormente focaram na análise do comportamento de motoristas utilizando simuladores e diferentes tipos de sensores. Outros trabalhos utilizam aparelhos de GPS para coleta dos dados, mas não analisam a periculosidade no comportamento dos motoristas. Janeja [19], por exemplo, utiliza os dados de GPS e o mapa geográfico para verificar se as trajetórias desviaram suas rotas pré-definidas, ou seja, se as trajetórias são anormais. Janeja ainda associa as regiões geográficas com características importantes, tais como regiões de narcotráfico, podendo dessa maneira identificar trajetórias que desviaram suas rotas para praticarem tráfico de narcóticos.

Alguns trabalhos focam no comportamento das trajetórias, mas sem destacar anomalias ou analisar periculosidade. Cao [22] [23] utiliza

os dados coletados por GPS para encontrar padrões de periodicidade no comportamento das trajetórias. Cao em seus dois trabalhos compara a localização dos objetos móveis com o tempo em que acontecem. É encontrado um comportamento periódico quando um objeto móvel está sempre num mesmo local num mesmo horário de dias diferentes. Di Lorenzo [29] propôs um algoritmo que é similar ao de Cao, porém ele sugere os prováveis locais onde os objetos móveis irão estar. Di Lorenzo verifica se existe uma periodicidade no histórico de movimentos de um objeto móvel. Se detectada a periodicidade e o momento da trajetória atual e a localização atendem ao próximo período, o destino deste movimento periódico é sugerido ao objeto móvel. Baglioni [16] identifica perfis de trajetórias através da análise de origem, destino e locais visitados obtidos com os dados de GPSs. O trabalho de Baglioni busca os locais importantes da trajetória onde o objeto permaneceu certo tempo (*stops*). Depois de encontrados os *stops* são verificados se esses locais são pontos turísticos, locais de trabalho, casas noturnas, entre outros, possibilitando classificar uma trajetória que tem origem num hotel, passa por museus, restaurantes em uma trajetória de turista. Siqueira [26] analisa padrões de comportamento individual em trajetórias objetivando encontrar perseguições entre duas trajetórias. Ele define diferentes padrões de perseguição e cria um algoritmo que descobre o padrão de perseguição em conjuntos de trajetórias. O algoritmo procura por padrões de perseguição em pares de trajetórias, e em seguida, define o tipo daquela perseguição. São levados em consideração, além da distância entre as trajetórias e o tempo em que estão acontecendo, também a duração mínima de uma perseguição. Embora Siqueira analise comportamento em trajetórias, ele não classifica em comportamentos normais ou anormais, pois o foco é no padrão de perseguição. Trasarti [27] [28] busca por perfis individuais em trajetórias possibilitando a descoberta de trajetórias que compartilham as mesmas rotinas diárias. Para descobrir as trajetórias que compartilham características ele separa os locais em que as trajetórias se mantêm paradas e chama de *stops*. Depois são separadas as subtrajetórias existentes entre os *stops* que são chamadas de *trips*. A partir disso as trajetórias que possuem uma distância máxima entre suas *trips* e que viajam em uma mesma periodicidade numa mesma direção são agrupadas como trajetórias que compartilham uma mesma *trip*. Dessa maneira o trabalho cria grupos de trajetórias que compartilham a mesma rotina diária, possibilitando a criação de um conceito de “carona solidária” onde, por exemplo, motoristas de veículos que compartilham uma trajetória poderiam ir juntos num único veículo. O trabalho de

Trasarti é baseado no comportamento de trajetórias, porém não encontra comportamentos normais e anormais, apenas cria grupos de trajetórias que compartilham de algumas características.

Até o presente momento apenas alguns trabalhos foram desenvolvidos utilizando dados de GPSs para a análise de periculosidade no comportamento de motoristas. Verroios [12], por exemplo, busca por veículos com comportamento perigoso a fim de enviar mensagens de alerta aos veículos nas proximidades, alertando sobre o perigo. Um comportamento perigoso pode ser, por exemplo, um carro saindo de uma via marginal e entrando em uma via principal com alta velocidade. O foco não está em descobrir os tipos de comportamentos perigosos, mas nos protocolos de comunicação, o formato e conteúdo das mensagens de alerta e na seleção dos carros a enviar e receber mensagens. A mensagem é enviada automaticamente pelo carro com comportamento anômalo para todos os carros que podem sofrer a colisão.

Liao [9] e Zhang [10] procuraram anomalias em trajetórias de táxis. Liao encontra comportamentos imprudentes dos motoristas de táxi, considerando velocidade, tempo, posição e informações sobre passageiros. Se a velocidade de um táxi é maior ou menor do que a velocidade normal da região (extraída de outras trajetórias de táxis que passam na mesma região) no mesmo período (manhã, hora do *rush* na manhã, meio-dia, à tarde, hora do *rush* à tarde, noite, tarde da noite) o motorista de táxi é considerado anormal. Zhang divide o espaço (mapa) em uma grade criando células. As trajetórias que têm a mesma origem e destino devem mover-se através das mesmas células na grade. A maioria das trajetórias que se movem ao longo das mesmas células são consideradas com um comportamento normal, enquanto que as trajetórias que percorrem outras células são consideradas anômalas.

De forma similar ao trabalho de Liao [9] e Zhang [10], Fontes [42] e Aquino [43] procuram por comportamentos anormais, chamados de *outliers*. Embora identifiquem como comportamento anormal ou *outlier* as trajetórias que desviam de um caminho padrão seguido pela maioria dos objetos móveis, não analisam o comportamento de direção do motorista, mas apenas a rota escolhida pelo mesmo.

Embora as obras anteriormente detalhadas analisam várias características de motoristas, a maioria delas não foram desenvolvidas para trajetórias reais e nem para classificar os motoristas em diferentes níveis de periculosidade. Além destas abordagens existentes, existem também ferramentas comerciais como *AA Car Insurance* [32] que avaliam o comportamento dos motoristas. Essas ferramentas, em geral,

avaliam o motorista baseando-se em movimentos individuais, e não comparam um comportamento a outras trajetórias ou a locais que possam ser causadores do comportamento anômalo, como proposto neste trabalho.

Este trabalho propõe encontrar movimentos bruscos, sem considerar sensores em pedais e sem considerar o comportamento de objetos (veículos) nas proximidades, mas simplesmente a análise da trajetória do objeto móvel gerada por GPS. Em resumo, são analisadas as seguintes propriedades de trajetórias individuais a fim de classificar o motorista em níveis de periculosidade: movimentos bruscos incluindo aceleração, desaceleração e mudanças de direção, a razão dos movimentos bruscos (locais que podem afetar o movimento como, por exemplo um engarrafamento ou um radar), movimentos bruscos repetitivos, a velocidade no momento do movimento brusco em relação à velocidade permitida na via percorrida, costura entre as faixas de trânsito e excesso de velocidade ao longo das trajetórias. Ainda, utilizando os movimentos bruscos encontrados, são destacados locais que possam ser os causadores dessas anomalias.

De maneira geral, os trabalhos e ferramentas comerciais previamente detalhados também analisam algumas características de motoristas, mas não foram desenvolvidos para utilizar trajetórias reais e/ou não classificam o comportamento dos motoristas em níveis de periculosidade. Ainda, nenhum tenta justificar as anomalias encontradas com fatores externos que possam ser causadores das anomalias e nem destacam esses locais como problemáticos. Na tabela 1 é possível perceber mais claramente as diferenças de alguns dos trabalhos destacados.

3 O MÉTODO PROPOSTO

O método proposto neste trabalho realiza dois passos principais. O primeiro é identificar subtrajetórias com movimentos bruscos, analisando acelerações bruscas, desacelerações bruscas e mudanças bruscas de direção ao longo das trajetórias. O segundo passo é analisar os movimentos bruscos de diferentes maneiras e então classificar os motoristas em níveis de periculosidade e apontar os locais “problemáticos” nas vias. A Seção 3.1 apresenta as definições básicas, a Seção 3.2 apresenta as definições necessárias para o método proposto, a Seção 3.3 apresenta as heurísticas para a classificação dos motoristas e a Seção 3.4 detalha o algoritmo proposto em duas partes.

3.1 DEFINIÇÕES BÁSICAS

Esta Seção apresenta alguns conceitos básicos sobre trajetórias. A maioria destes conceitos são baseados em Fontes [42]. Os conceitos básicos são iniciados com os conceitos de ponto, trajetória e subtrajetória.

Definição 1. Ponto. Um ponto p é uma tupla (x, y, t) , onde x e y são a latitude e longitude representadas no espaço e t é o tempo em que o ponto foi coletado.

Uma lista ordenada de pontos define uma trajetória.

Definição 2. Trajetória. Uma trajetória T é uma lista $\langle tid, p_1, p_2, p_3, \dots, p_n \rangle$, onde tid é o identificador da trajetória e $p_j = (x_j, y_j, t_j)$ e $t_1 < t_2 < t_3 < \dots < t_n$.

Em geral, uma trajetória não apresenta o mesmo comportamento ao longo de seu percurso. Por isso, as trajetórias são divididas em partes chamadas de subtrajetórias. Uma subtrajetória pode ser definida como um segmento de uma trajetória conforme segue:

Definição 3. Subtrajetória. Uma subtrajetória s de T é uma lista $\langle tid, p_k, p_{k+1}, \dots, p_l \rangle$, onde tid é o identificador da trajetória e $p_k \subset T$ e $k \geq 1$ e $l \leq n$.

3.2 DEFINIÇÕES PRINCIPAIS

A primeira análise a ser efetuada para caracterizar o comportamento de motoristas é verificar a variação da velocidade ao longo dos pontos das trajetórias em busca de movimentos bruscos.

Definição 4. Variação da velocidade entre pontos. A variação da velocidade v de um ponto p_i para p_j pertencentes a uma trajetória T é a diferença da velocidade do ponto p_j para o ponto p_i , $(Vp_j - Vp_i)$, onde o instante do ponto p_j é maior que o instante do ponto p_i , $(t_j > t_i)$.

Quando há uma variação na velocidade ao longo dos pontos de uma trajetória, caracteriza-se uma aceleração ou uma desaceleração. Nas situações em que a velocidade do objeto móvel aumenta entre os pontos, ocorrendo uma variação positiva na velocidade, caracteriza-se uma *aceleração*. Já nas situações em que a velocidade da trajetória diminui entre os pontos, ocorre uma variação negativa na velocidade, caracterizando uma *desaceleração*.

Neste trabalho é considerada brusca qualquer variação da velocidade (aceleração, desaceleração e mudança de direção) de uma subtrajetória que seja acima de certo limiar máximo permitido. Em física, aceleração é definida como a variação da velocidade dividida pela variação do tempo. Nesta dissertação, aceleração é definida como brusca quando a variação é maior do que um dado limiar chamado de *minA*.

Definição 5. Aceleração Brusca. A aceleração de um ponto p_i para um ponto p_j de uma trajetória, onde $t_j > t_i$, é considerada brusca se

$$\frac{v_{p_j} - v_{p_i}}{t_j - t_i} > \text{minA}, \text{ e } \text{minA} > 0.$$

Similarmente, define-se *desaceleração brusca* uma aceleração negativa com um valor maior que certo limiar de desaceleração chamado *minD*.

Definição 6. Desaceleração Brusca. A desaceleração de um ponto p_i para um ponto p_j de uma trajetória, onde $t_j > t_i$, é considerada brusca se $\frac{v_{pj} - v_{pi}}{t_j - t_i} * (-1) > \min D$, e $\min D > 0$.

A figura 2 apresenta o trecho de uma trajetória real com pontos de aceleração e desaceleração, que podem ser observados pelos valores de aceleração, sendo positivas as subtrajetórias com aceleração, negativas com desaceleração e valores zerados representam movimentos retilíneos uniformes, ou seja, sem variação de velocidade. Para exemplificar, foi considerado que os limites aceitáveis de aceleração e desaceleração são 4 m/s^2 e -4 m/s^2 , respectivamente. Pode-se perceber na figura que além das acelerações e desacelerações normais, os pontos no local destacado mais escuro (vermelho), próximo ao tempo 13:17:45, apresentam uma desaceleração brusca, onde se tem uma sequência de 2 pontos com valores de desaceleração menores que -4 m/s^2 . Já os pontos mais claros (amarelo), destacados próximo ao tempo 13:17:57, apresentam aceleração brusca, pois os valores de aceleração excedem o limite de 4 m/s^2 . Se os valores de aceleração forem interpretados apenas olhando o gráfico da figura 2, é possível inferir que o veículo seguiu realizando uma desaceleração brusca no instante 13:17:45, estabilizou a velocidade em 13:17:49, onde há uma sequência de pontos com aceleração zero, e logo após uma aceleração brusca no instante 13:17:57. Essa característica é comum em semáforos, onde o condutor reduz bruscamente a velocidade, permanece parado por um tempo e depois acelera o veículo rapidamente para chegar a uma velocidade alta.

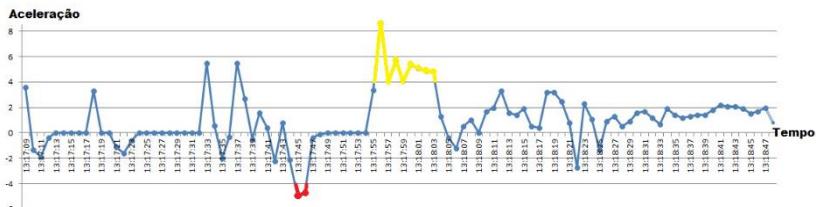


Figura 2. Trajetória com aceleração brusca e desaceleração brusca.

A terceira análise está relacionada à mudança brusca de direção, que é a situação onde um objeto móvel muda bruscamente a sua direção. Mudanças na direção da trajetória de um objeto móvel também podem caracterizar o comportamento do indivíduo. Podemos considerar que um

objeto que muda a sua direção bruscamente caracteriza um mau comportamento e uma situação anormal.

Uma mudança normal de direção é uma situação em que um objeto muda de direção e sua velocidade não está alta a ponto de gerar desconforto.

Enquanto em Carboni e Bogorny [11] uma mudança brusca de direção era representada por uma curva em alta velocidade, aqui é utilizada a força centrípeta. Sempre que um corpo se movimenta em uma trajetória não retilínea, age sobre ele uma força cujo efeito é alterar sua direção, para que o objeto móvel possa percorrer a curva. Essa força é chamada de força centrípeta. Ela é uma força que mantém um corpo em movimento com uma velocidade uniforme ao longo de um caminho circular e é dirigido ao longo do raio em direção ao centro [1]. Neste trabalho, define-se mudança brusca de direção quando a aceleração centrípeta é maior que certo limiar chamado *minC*.

Definição 7. Mudança brusca de direção. Dado v_p como a velocidade do objeto móvel no ponto p e r como o raio da curva, uma mudança de direção é brusca se e somente se a aceleração centrípeta

$$\frac{v_p^2}{r} > \text{minC}.$$

Utilizando as definições citadas anteriormente é possível encontrar os pontos das trajetórias que apresentam comportamentos de aceleração brusca, desaceleração brusca e mudança brusca de direção, e dessa maneira definir subtrajetórias com movimentos bruscos ao longo das trajetórias.

Definição 8. Movimento Brusco. Uma subtrajetória s tem um movimento brusco se apresentar uma aceleração brusca ou uma desaceleração brusca ou uma mudança brusca de direção.

Uma vez definidos os movimentos bruscos, estes podem ocorrer em virtude de diferentes razões. Por exemplo, podem acontecer em um local com uma lombada não sinalizada, por algum problema na via, por um evento não esperado como um pedestre atravessando a rua, e não necessariamente por culpa do motorista.

Lombadas não sinalizadas, fiscalizações policiais, buracos nas estradas e outros fatores podem causar movimentos bruscos não necessariamente pela má condução dos motoristas. Esses locais

conhecidos que possam ser causadores de anomalias são definidos como sendo um *lugar de interesse* ou uma *feição de interesse*.

Feição de interesse é definida pelo Open GeoSpatial Consortium [17] como sendo um lugar geográfico de interesse. Mais especificamente feição de interesse é definida na Definição 9, similar a definição de Alvares [14].

Definição 9. Feição de Interesse. Uma feição de interesse e é uma tupla $(R, tipo)$, onde R é um polígono topologicamente fechado no espaço bidimensional \mathbb{R}^2 , representando a feição, e $tipo$ é a categoria da feição.

Exemplos de feições de interesse são lugares previamente conhecidos e que poderiam ser uma possível causa para um motorista realizar um movimento brusco, como uma escola, onde a velocidade praticada na rua é geralmente muito menor do que em outros pontos da mesma rua, um semáforo, um posto de polícia, uma patrulha da polícia ou até mesmo uma faixa de pedestres, onde o R representa a geometria da feição e $tipo$ é a categoria (escola, semáforo, etc.). Note que as feições são sempre polígonos.

Um conjunto finito de feições de interesse é representado por $E = \{e_1 = (Re_1, tipoe_1), \dots, e_n = (Re_n, tipoe_n)\}$.

Com o conhecimento das feições de interesse é possível encontrar os movimentos bruscos nas trajetórias e verificar se existe ou não alguma feição de interesse próxima a subtrajetória de movimento brusco. Caso a maioria das trajetórias que passam por determinada área no espaço possuam subtrajetórias com anomalias que se intersectam nesse espaço e não exista nenhuma feição de interesse que justifique tais anomalias, pode-se considerar que foi encontrado um *local problemático* e que o mesmo está gerando anomalias naquela área.

Definição 10. *Local Problemático*. Seja R o conjunto dos números reais e \mathbb{R}^2 o espaço bidimensional. Seja E o conjunto de feições de interesse, DB o conjunto das trajetórias do banco de dados, $minTraj$ um percentual das trajetórias do banco de dados e S o conjunto de subtrajetórias com movimento brusco. Um *Local Problemático* l é um polígono em \mathbb{R}^2 se, e somente se,

$$l \cap E.R = \emptyset \wedge \frac{|(l \cap S) \neq \emptyset|}{|(DB \cap l) \neq \emptyset|} > minTraj.$$

Ainda, motoristas que ficam trocando de faixa frequentemente podem caracterizar pressa e/ou nervosismo, gerando perigo. Trocas constantes de faixa caracterizam um mau comportamento do motorista. Uma mudança entre faixas é dada pela sequência de pontos de uma trajetória com uma variação da direção maior do que 10° e em seguida volta para a mesma direção. O valor de 10° foi utilizado com base em simulações reais, como demonstrado na figura 3. A figura 3 mostra uma subtrajetória com os pontos p_1 ao p_7 . Entre as retas $\overline{p_3p_4}$, $\overline{p_4p_5}$ e $\overline{p_5p_6}$ existe uma mudança de faixa. Destaca-se que a mudança do ângulo entre a reta $\overline{p_3p_4}$ para a reta $\overline{p_4p_5}$ é de 18° , e a mudança do ângulo entre $\overline{p_4p_5}$ para $\overline{p_5p_6}$ é de 12° . Considerando esta situação real, o valor de 10° é utilizado como o limite mínimo em uma mudança de direção para que seja encontrada uma mudança de faixa. Outra premissa assumida é que quando um motorista muda de faixa a velocidade da trajetória deve ser superior a 10 Km/h. O valor de 10 Km/h foi usado para representar um carro em movimento e reduzir os falsos positivos gerados pelo ruído do GPS quando os veículos estão parados.

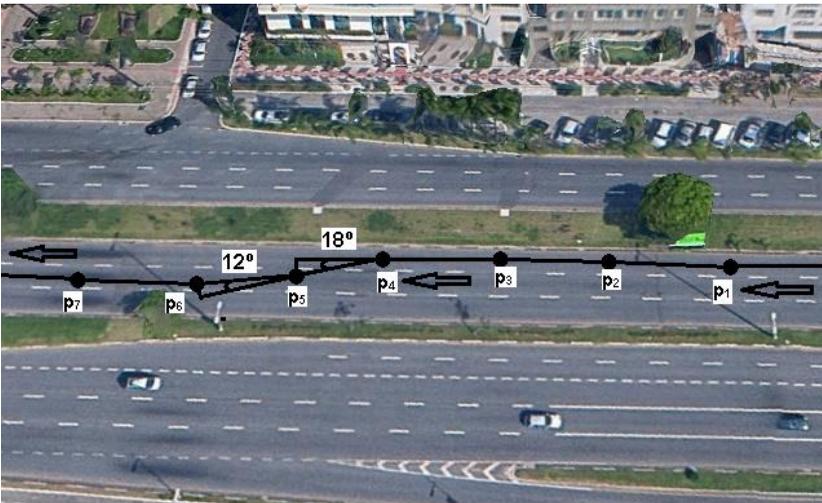


Figura 3. Exemplo de troca de faixa.

Mas nem sempre uma troca de faixa pode caracterizar uma manobra perigosa. Uma manobra perigosa é caracterizada por uma sequência de trocas de faixa, caracterizando uma *costura entre faixas*. Para diferenciar uma *troca de faixa* de uma *costura entre faixas* foi

definido neste trabalho que devem existir três ou mais mudanças de faixa em uma sequência. Uma mudança de faixa simples representa um motorista simplesmente trocando de faixa, como pode ser observado na figura 4(a). Duas mudanças de faixa podem representar uma ultrapassagem, conforme ilustra a figura 4(b), já três mudanças de faixa caracterizam uma costura entre faixas, conforme demonstrado na figura 4(c).

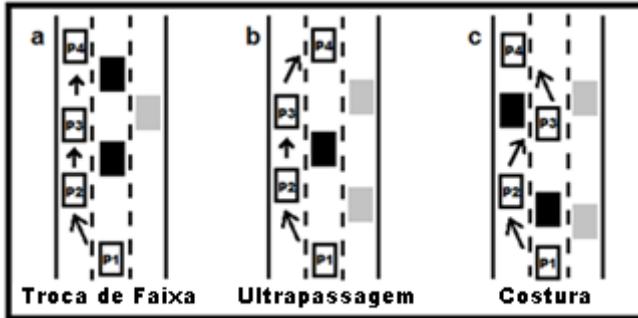


Figura 4. Troca de Faixa, Ultrapassagem e Costura

Tendo demonstradas as diferenças entre *troca de faixa* e *costura entre faixas*, é possível descrever a primeira de acordo com a definição 11.

Definição 11. *Troca de faixa.* Seja $S = \langle p_k, p_{k+1}, p_{k+2}, p_{k+3} \rangle$ uma subtrajetória. A subtrajetória S é uma troca de faixa f se e somente se $\hat{\text{ângulo}}(\overrightarrow{p_k p_{k+1}}, \overrightarrow{p_{k+1} p_{k+2}}) > 10^\circ \wedge \hat{\text{ângulo}}(\overrightarrow{p_{k+1} p_{k+2}}, \overrightarrow{p_{k+2} p_{k+3}}) > 10^\circ \wedge V_{p_{k+1}} > 10 \text{ Km/h} \wedge V_{p_{k+2}} > 10 \text{ Km/h}$. Uma troca de faixa é dada por uma tupla $f = (\text{start}T, \text{end}T)$, onde $\text{start}T = p_k.t \wedge \text{end}T = p_{k+3}.t$.

Para que uma costura seja encontrada é necessário que ocorram no mínimo três trocas de faixa sequencialmente, ou seja, em um curto período de tempo. Com uma sequência de três trocas de faixa é possível definir a costura entre faixas como:

Definição 12. *Costura entre faixas.* Seja $TF = \langle f_1, f_2, f_3, \dots, f_n \rangle$ a sequência de trocas de faixa de uma trajetória T . Uma sequência $\langle f_i, f_{i+1}, f_{i+2} \rangle \subset TF$ é uma costura entre faixas se e somente se $f_{i+2}.\text{end}T - f_i.\text{start}T < 30s$.

3.3 HERÍSTICAS PARA ANÁLISE E CLASSIFICAÇÃO DOS MOTORISTAS

Depois de apresentadas as definições da Seção anterior, é preciso definir os critérios / heurísticas de análise dos movimentos nas trajetórias para definir o comportamento de um motorista. Por exemplo, um motorista que realiza uma desaceleração brusca frente a um evento inesperado não pode ser considerado um mau motorista. Já um motorista que possui movimentos bruscos ocasionados por excesso de velocidade pode ser considerado um mau motorista pelo fato de estar gerando perigo diretamente relacionado ao seu comportamento no trânsito. Por esses motivos, define-se para este trabalho um conjunto de heurísticas / características presentes nas trajetórias para classificar os motoristas em mais cuidadosos ou mais perigosos. As seguintes características foram definidas para classificar os motoristas em níveis de periculosidade:

F1: *Movimentos bruscos* que tem *intersecção* com uma ou mais *feições de interesse* pré-definidas poderiam ser a *razão da anomalia*, e assim não necessariamente caracterizam um mau motorista.

F2: *velocidade acima do limite da via*: se a velocidade do veículo quando o movimento brusco é iniciado em relação à velocidade da via for superior ao limite máximo permitido pode caracterizar um mau motorista.

F3: *movimentos bruscos comuns*: são trajetórias de objetos diferentes que compartilham um movimento brusco similar, ou seja, um movimento brusco no mesmo local geográfico. Quando várias trajetórias têm o mesmo movimento brusco na mesma área geográfica, isso pode caracterizar um problema relacionado ao lugar, e não necessariamente ao motorista. Por exemplo, uma estrada em mau estado ou uma lombada não sinalizada podem levar a movimentos bruscos em várias trajetórias, e não necessariamente caracteriza um mau motorista.

F4: *repetitivos movimentos bruscos individuais*. Uma trajetória com vários movimentos bruscos caracteriza uma trajetória anômala, podendo caracterizar um mau motorista.

F5: *maior parte da trajetória em excesso de velocidade*: Uma trajetória possui a maioria da velocidade em excesso quando a maior parte dos pontos da trajetória possui velocidade superior a um dado

limite máximo de velocidade. Motoristas com trajetórias deste tipo demonstram comportamento anômalo.

F6: costuras entre faixas. Uma trajetória que possui costura entre as faixas está relacionada ao comportamento do motorista. Essa situação pode caracterizar nervosismo e agressividade do motorista apressado que tenta ultrapassar todos os carros que estão trafegando em sua frente, gerando perigo e ocasionando risco de acidente envolvendo outros veículos.

Com base nas definições e heurísticas apresentadas anteriormente, bem como as suas contribuições, são propostas as seguintes categorias de níveis de periculosidade para os motoristas:

Nível 1 (Cuidadoso): um motorista é cuidadoso quando suas trajetórias não possuem anomalias. Considera-se que é interessante para algumas aplicações o reconhecimento de bons motoristas.

Nível 2 (Distraído): um motorista é distraído quando possui subtrajetórias com movimentos bruscos e estas subtrajetórias intersectam feições de interesse ou intersectam subtrajetórias de outros objetos com comportamento semelhante.

Nível 3 (Perigoso): um motorista é considerado perigoso quando possui subtrajetórias com um dos seguintes comportamentos: (i) movimentos bruscos em lugares sem intersecção com feições de interesse ou (ii) mais de uma subtrajetória com movimento brusco ou costuras.

Nível 4 (Muito Perigoso): um motorista é considerado muito perigoso quando possui movimentos bruscos com velocidade acima do limite de velocidade da via e possui mais do que a metade de seu percurso em excesso de velocidade. Além disso, deve ter subtrajetórias com um dos seguintes comportamentos: (i) várias subtrajetórias com movimentos bruscos ou costura, (ii) movimentos bruscos que não intersectam movimentos bruscos de outras trajetórias, (iii) movimentos bruscos em lugares sem justificativas (sem inersecção com feições de interesse).

3.4 O ALGORITMO PROPOSTO

Uma vez definidos os principais critérios para análise de comportamento dos motoristas, é possível ilustrar o algoritmo para

extrair os padrões das trajetórias e classificá-las em níveis. O algoritmo em alto nível é ilustrado na figura 5.

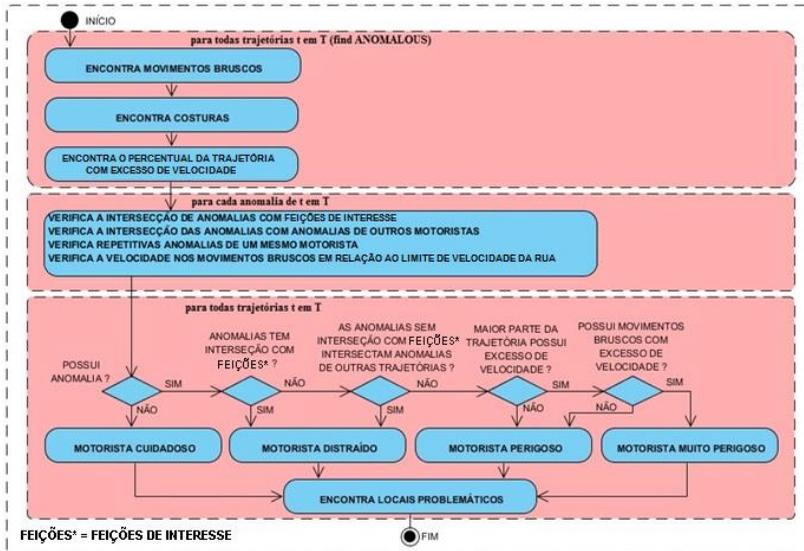


Figura 5. Fluxo do Algoritmo.

Observando a figura 5, primeiramente são percorridas todas as trajetórias e identificados os movimentos bruscos (subtrajetórias) com base em acelerações bruscas, desacelerações bruscas e mudanças bruscas de direção. Depois disso são encontradas as costuras. Logo após é calculado o percentual da trajetória que está com excesso de velocidade em relação a velocidade permitida na via percorrida. Estes passos estão no primeiro quadro da figura 5.

Uma vez detectadas as anomalias, elas são verificadas para ver se intersectam feições de interesse, se intersectam anomalias de outros motoristas, se os motoristas possuem muitas anomalias (repetitividade de anomalias) e se os movimentos bruscos possuem excesso de velocidade em relação ao limite da via percorrida (quadro 2 da figura 5).

Por fim, na terceira parte é efetuada a análise dos resultados encontrados e gerada a classificação dos motoristas. Após a classificação dos motoristas são encontrados os locais que podem ser causadores de anomalias, ou seja, os locais problemáticos.

Antes de detalhar o pseudo-algoritmo ilustrado em Part1, é importante destacar que o algoritmo proposto analisa o movimento

brusco a cada três pontos, para evitar que um ruído (imprecisão do GPS) possa caracterizar tal movimento. Se forem analisados dois pontos, um deles pode ser ruído e afetar o resultado. Através da figura 6 é possível visualizar uma trajetória com a velocidade representada no eixo Y e tempo no eixo X. No instante de tempo 14:51:29 houve uma falha do GPS e esta falha causa uma desaceleração e aceleração brusca em análises de dois pontos.

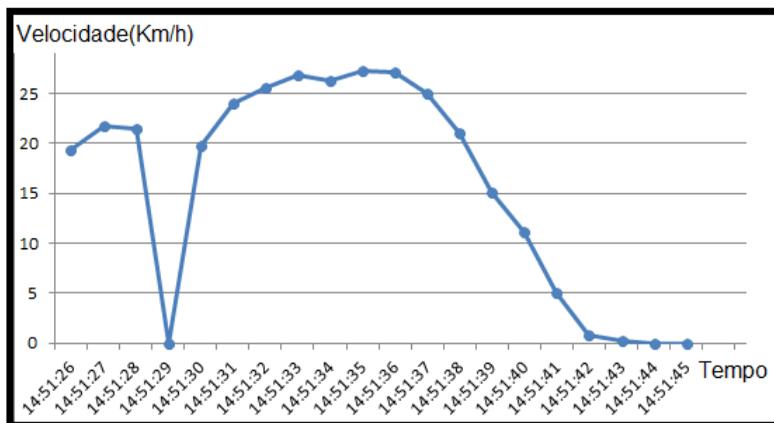


Figura 6. Pontos de trajetória (Velocidade x Tempo) com falha de coleta.

Já a figura 7 demonstra um gráfico também mostrando a variação da velocidade no eixo Y e tempo no eixo X, com uma desaceleração brusca encontrada e destacada nos instantes 15:39:44, 15:39:45 e 15:39:46. Essa desaceleração brusca não seria encontrada caso houvessem sido considerados quatro pontos desacelerando sequencialmente. Quatro pontos pode ser um número elevado para movimentos bruscos como aceleração e desaceleração. Por isso, optou-se pela análise dos pontos de três em três.

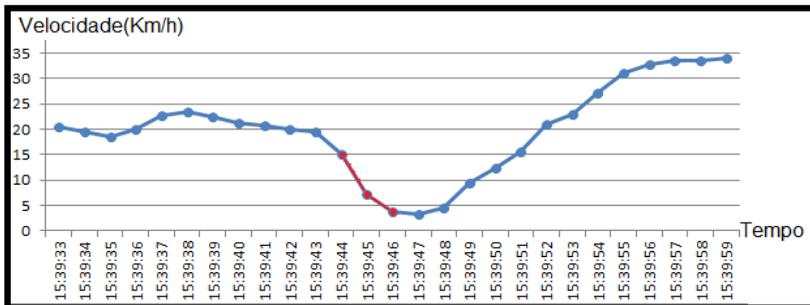


Figura 7. Sequência de pontos de trajetória (Velocidade x Tempo).

O pseudo código do algoritmo é dividido em duas etapas principais: *findAnomalous*, o qual é mostrado na Parte 1 e *driverClassifier* na Parte 2.

A parte 1 do algoritmo tem como entrada o conjunto de trajetórias T (linha 01), o limiar usado para a aceleração, desaceleração e mudança de direção (linhas 02, 03 e 04), o limite *minS* utilizado como o limite de velocidade caso não exista o conjunto de ruas com os limites de velocidade (linha 05) e se existir, o conjunto das ruas com o limite de velocidade das vias W (linha 06). Para cada trajetória (linha 07) o algoritmo analisa todos os pontos (linha 08) a fim de encontrar anomalias. Se houver uma subtrajetória com pelo menos três pontos com aceleração brusca (linha 09), ela é armazenada em uma lista de movimentos bruscos (linha 10). O mesmo teste é realizado para encontrar subtrajetórias com desaceleração brusca (linhas 11 e 12). O passo seguinte é encontrar o raio das curvas da trajetória (linha 13) para analisar as mudanças bruscas de direção. A Figura 8 mostra como o raio é calculado. São considerados 3 pontos sequenciais p_1 , p_2 e p_3 . A partir destes pontos são criados os segmentos de linha $\vec{p_1p_2}$ e $\vec{p_2p_3}$. Duas linhas perpendiculares $\vec{l_1}$ e $\vec{l_2}$ são criadas atravessando o centróide de $\vec{p_1p_2}$ e $\vec{p_2p_3}$. O ponto em que $\vec{l_1}$ e $\vec{l_2}$ se cruzam é o centro da curva. A distância a partir do ponto de intersecção para p_2 é o raio da curva.

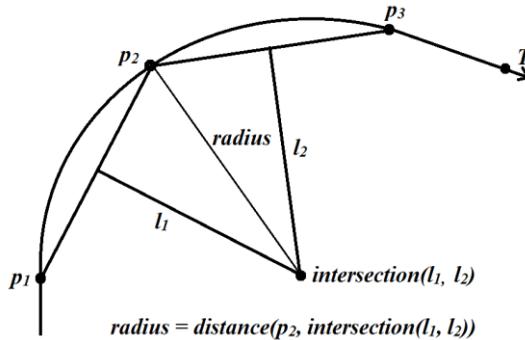


Figura 8. Raio da Curva

Após calcular o raio da curva o algoritmo calcula a aceleração centrípeta do movimento para descobrir as subtrajetórias com mudança brusca de direção (linha 14) e adiciona essas subtrajetórias à lista de movimentos bruscos (linha 15).

Depois de comparar os pontos para encontrar movimentos bruscos, o algoritmo analisa a velocidade “geral” da trajetória, procurando pelos pontos das trajetórias que estão com velocidade maior que o limite $minS$ (linha 16) e adiciona em uma lista específica (linha 17), caso não se tenha o conjunto de ruas W . Caso W tenha sido informado, é comparada a velocidade da via onde a trajetória percorre com a velocidade da trajetória. Se o valor limite de velocidade da via que intersecta o ponto é menor que a velocidade do ponto, (linha 18) este é adicionado numa lista com os pontos em excesso de velocidade (linha 19).

Na linha 20 o algoritmo verifica as trocas de faixa com a função *lane_change* (conforme explicado na Definição 11), utilizando como parâmetros os quatro pontos p_1 , p_2 , p_3 e p_4 para formar as retas $\overline{p_1p_2}$, $\overline{p_2p_3}$, $\overline{p_3p_4}$ e $\overline{p_4p_5}$ e encontrar trocas de faixa conforme demonstrado na figura 3. Se as diferenças de ângulo descritas anteriormente são maiores do que 10° e o objeto móvel estiver em movimento (com velocidade maior que 10 Km/h) o movimento é uma troca de faixa e os pontos são adicionados em uma lista de trocas de faixa (linha 21) para a posterior verificação de costura entre faixas. Se a condição da linha 20 não é atendida, mas a utilização da mesma função com cinco pontos sequenciais é atendida, o algoritmo encontra uma troca de faixa com cinco pontos (linha 22) e adiciona os pontos na lista de trocas de faixa (linha 23). As trocas de faixa são verificadas com diferentes números de

pontos sequenciais para que possam ser encontradas trocas de faixa mais curtas com quatro pontos, ou um pouco mais longas, com cinco pontos. Trocas de faixa com pontos acima de cinco já são consideradas trocas de faixa mais lentas e que não podem caracterizar uma costura, pois esta é uma ação rápida.

Uma vez analisados todos os pontos de uma trajetória (laço da linha 08 até a linha 24), o algoritmo analisa as anomalias desta trajetória, iniciando pela costura. Nas linhas 25, 26 e 27 o algoritmo analisa as trocas de faixa adicionadas na lista de trocas de faixa, a fim de encontrar mudanças que ocorrem em um curto período de tempo (intervalos de no máximo 30 segundos) e caracterizar uma costura, como explicado na Definição 12. Se uma costura entre faixas é encontrada, o algoritmo adiciona a trajetória a uma lista de trajetórias com este comportamento específico (linha 28).

O próximo passo é verificar a quantidade de pontos da trajetória em questão que possuem excesso de velocidade. Se a maioria (mais de 50%) dos pontos de uma trajetória foram computados como tendo excesso de velocidade, a trajetória é adicionada a uma lista de trajetórias que possuem maioria da velocidade em excesso (linhas 31 e 32). Concluindo a análise de uma trajetória, o algoritmo limpa as duas listas usadas para trocas de faixa e pontos com excesso de velocidade (linhas 33 e 34) e retorna a linha 7 para dar início a análise da segunda trajetória, percorrendo o mesmo processo até analisar toda a base de trajetórias.

Por fim, após verificar todas as trajetórias o algoritmo retorna as listas de movimentos bruscos, de trajetórias com costura entre faixas e a lista de trajetórias com mais da metade dos pontos com excesso de velocidade (linha 36).

Part 1: findAnomalous

Input:

```
(01) T           // conjunto de trajetórias
(02) minA       //valor limite para aceleração
(03) minB       //valor limite para desaceleração
(04) minC       //valor limite para mudança de direção
(05) minS       //valor limite de velocidade a ser utilizado caso W seja nulo
(06) W          // conjunto das vias com limites de velocidade
```

Method:

```
(07) for (i=0; i<= count(T.tid); i++)           // para cada trajetória T
(08) for (p=0, p< trajectory.size - 2, p++) // para cada ponto p em T(i)
(09) if ((vp+2-vp+1) / (tp+2-tp+1) > minA AND ((vp+1-vp) / (tp+1-tp) > minA)
(10)   abruptList.add(T.tid, (p), (p+1));     end if;
(11) if ((vp+2-vp+1) / (tp+2-tp+1) * -1 > minD AND ((vp+1-vp) / (tp+1-tp) * (-1) > minD)
(12)   abruptList.add(T.tid, (p), (p+1));     end if;
(13) r = getRadius(p, p+1, p+2);
(14) if ((vp/r) > minC AND (vp+1/r) > minC AND (vp+2/r) > minC
(15)   abruptList.add(T.tid, (p), (p+1));     end if;
(16) if (W = null AND vp > minS) // analisa velocidade geral da trajetória
(17)   speedList.add(p);                       end if;
(18) if (W ≠ null AND W.getSpeed(W.the_geom ∩ p) < vp)
(19)   speedList.add(p);                       end if;
(20) if (lane_change(p, p+1, p+2, p+3) is true)
(21)   laneList.add(p, p+1, p+2, p+3);
(22) elseif (lane_change(p, p+1, p+2, p+3, p+4) = true)
(23)   laneList.add(p, p+1, p+2, p+3, p+4); end if;
(24) end for;
(25) for (p=0, p< laneList.size - 1, p++) // para cada mudança de faixa
(26) for (q=0, q< laneList.size - 1, q++) // para cada mudança de faixa
(27) if (laneList.get(q).time > laneList.get(p).time+30 AND p < q)
(28)   laneCutList.add(T.tid);                 end if;
(29) end for;
(30) end for;
(31) if ((count(T.tid)/2) < speedList.size)
(32)   speedAllList.add(T.tid);                 end if;
(33) speedList.clear(); // limpa a lista para utilização na próxima trajetória
(34) laneList.clear(); // limpa a lista para utilização na próxima trajetória
(35) end for;
(36) return abruptList(), laneCutList(), speedAllList();
```

A segunda parte do algoritmo (parte 2) basicamente classifica as trajetórias através da análise dos movimentos anômalos e encontra os locais problemáticos nas vias. O algoritmo recebe como entrada o conjunto de trajetórias (linha 01), o conjunto de subtrajetórias com movimentos bruscos (linha 02), a lista das trajetórias com costura entre faixas (linha 03), a lista de trajetórias com a maior parte do tempo com velocidade em excesso (linha 04), o conjunto de ruas W (linha 05), o conjunto de feições de interesse E (linha 06) e o percentual mínimo de trajetórias necessário para que uma área seja considerada um local problemático (linha 07).

Para encontrar subtrajetórias com movimentos bruscos nos mesmos lugares é necessário verificar se subtrajetórias anômalas de trajetórias diferentes se intersectam. Essa intersecção será geralmente paralela e não perpendicular, pois são trajetórias que se movem nas mesmas ruas. Por isso, é preciso aumentar a área das subtrajetórias com essas anomalias, criando um *buffer* (linha 08) no entorno das subtrajetórias com movimentos bruscos. Como os movimentos bruscos são formados por poucos pontos, o *buffer* é necessário para captar as intersecções com outras anomalias no mesmo local, com as vias e com as feições de interesse. Após alguns experimentos foi encontrado 10 metros como uma boa medida para o *buffer*.

O algoritmo inicia comparando cada subtrajetória anômala (linha 09) com todas as outras subtrajetórias anômalas (linha 11). É verificado se uma trajetória possui subtrajetórias com movimentos anômalos onde nenhuma outra trajetória apresenta anomalia semelhante (linha 12) e um indicador é utilizado como verdadeiro (linha 13). Se uma trajetória tem várias subtrajetórias com movimentos bruscos (linha 14) ela é adicionada a uma lista de trajetórias com anomalias repetitivas (linha 15). Se uma trajetória foi identificada na linha 12 como tendo subtrajetórias com movimentos anômalos onde nenhuma outra trajetória apresenta anomalia semelhante (linha 17), essa trajetória é adicionada à lista de trajetórias com anomalias individuais (linha 18).

O próximo passo é verificar se as subtrajetórias anômalas intersectam feições de interesse (linha 19). Caso não intersectem, a trajetória é adicionada a uma lista de trajetórias que possuem anomalias que não intersectam feições de interesse (linha 20). Se a anomalia não intersectar feições de interesse, é verificado o número de trajetórias que passaram naquele mesmo local e o número de trajetórias que compartilham aquele movimento anômalo geograficamente (linha 21) de acordo com a Definição 10. Caso mais do que $minTraj$ do total de trajetórias que passaram por aquela área com anomalia tiveram a

subtrajetória anormal em comum, este área é adicionada em uma lista de locais problemáticos *L* (linha 22).

Em seguida, o algoritmo verifica a velocidade nos movimentos bruscos. Se o limite máximo de velocidade da via percorrida é menor do que a velocidade da subtrajetória com movimento brusco (linha 23), então a trajetória é adicionada a uma lista de trajetórias com movimentos bruscos em excesso de velocidade (linha 24). É importante notar que neste ponto se compara a velocidade da subtrajetória do objeto em relação à velocidade da via percorrida apenas quando um movimento brusco acontece. A intenção é descobrir se um movimento brusco de desaceleração ou mudança de direção foi causado repentinamente por ter sido iniciado em alta velocidade.

Tendo analisado as subtrajetórias anômalas, o algoritmo começa a classificar as trajetórias uma por uma (linha 26). A trajetória é classificada como nível 4 (Muito Perigosa) nas linhas 27 e 28, como de nível 3 (Perigosa) nas linhas 29 e 30, como de nível 2 (Distraída) nas linhas 31 e 32 e como Nível 1 (Cuidadosa) na linha 33. O retorno do algoritmo é uma lista com todas as trajetórias classificadas em um dos níveis de periculosidade previamente definidos e os locais destacados como problemáticos *L* (linha 34).

*Part 2: driverClassifier**Input:*

```

(01) T // conjunto de trajetórias
(02) abruptList; // lista de movimentos bruscos
(03) laneCutList; // lista de trajetórias com costura
(04) speedAllList; // conjunto de trajetórias com excesso de velocidade
(05) W; // conjunto de vias com limites de velocidade
(06) E; // conjunto de feições de interesse
(07) minTraj; // valor limite de trajetórias para locais problemáticos

```

Method:

```

(08) buffer (anomalousList.the_geom, 10); //aumento área das anomalias em 10m
(09) for each anomaly i in abruptList //para cada anomalia
(10)     IND = 'TRUE'; //Anomalias individuais(sem intersecção de outras)
(11)   for each anomaly j in abruptList
(12)     if((i.the_geom ∩ j.the_geom) ≠ ∅ AND i.tid ≠ j.tid)
(13)       IND = 'FALSE'; end if; //Anomalias que intersectam outras anomalias
(14)     if((i.the_geom ∩ j.the_geom) = ∅ AND i.tid = j.tid)
(15)       repeatList.add(i.tid);end if; //Trajetórias com mais de uma anomalia
(16)   end for;
(17)   if (IND = 'TRUE') //Se não há intersecção de outras anomalias
(18)     trajectoryList.add(i.tid); end if;
(19)   if((i.the_geom ∩ E.the_geom) = ∅) {/não ∩ nenhuma feição de interesse
(20)     nonEventList.add(i.tid);
(21)     if(count(T.the_geom ∩ abruptList.the_geom)) > minTraj)
(22)       L.add(i.tid, i.the_geom);end if;end if; //L. Problemáticos
(23)   if(W.getSpeed(W.the_geom ∩ i.the_geom) < i.speed)
(24)     speedList.add(i.tid); end if; //Excesso de velocidade em mov. brusco
(25) end for;
(26) for(i=0; i<= count(T.tid); i++) // para cada trajetória T
(27)   if((i.tid in speedList.tid) AND(i.tid in speedAllList.tid)
      AND(i.tid in (nonEventList.tid, i.tid in repeatList.tid,
                    i.tid in trajectoryList.tid, i.tid in laneCutList.tid)))
(28)     level.add(i.tid, 'LEVEL4');
(29)   elseif(i.tid in nonEventList.tid OR i.tid in (
      repeatList.tid, laneCutList.tid))
(30)     level.add(i.tid, 'LEVEL3');
(31)   elseif((i.tid not in nonEventList.tid) AND (i.tid not in
      trajectoryList.tid) AND (i.tid in anomalousList))
(32)     level.add(i.tid, 'LEVEL2');
(33)   else level.add(i.tid, 'LEVEL1'); end if;
(34) end for; return level(), L();

```

4 EXPERIMENTOS

A avaliação do comportamento dos motoristas pode ser diferente de acordo com o meio de transporte utilizado. Por exemplo, os movimentos bruscos de carros são diferentes de movimentos bruscos de ônibus e caminhões, devido ao tamanho e peso dos veículos. Por esse motivo foram realizados experimentos com diferentes tipos de veículos. Nessa dissertação são demonstrados resultados de experimentos com trajetórias reais tanto de carros quanto de ônibus.

Como os movimentos bruscos acontecem rapidamente, é preciso que o intervalo de tempo de coleta de pontos seja pequeno. A melhor identificação dos movimentos bruscos são em trajetórias com pontos amostrados com frequência de 1 ou poucos segundos. Nesse trabalho foram realizados experimentos com um conjunto de trajetórias de caminhões com taxa de amostragem de 30 segundos. Contudo, os movimentos anômalos não foram identificados. Dessa forma, optou-se por trajetórias de carros e de ônibus, cujo intervalo de coleta entre os pontos foi de 1 segundo.

4.1 ANÁLISE DE TRAJETÓRIAS DE VEÍCULOS DE PASSEIO

O primeiro conjunto de dados é de carros de passeio, composto por 64 trajetórias, com pontos coletados em intervalos de 1 segundo, no estado de Santa Catarina. Os dados foram coletados em dois momentos. Primeiramente no ano de 2011 e depois em 2013. Para este experimento tem-se o conjunto de vias com os respectivos limites de velocidade permitidos e um conjunto de feições de interesse composto por semáforos, faixas de pedestres, escolas e redutores de velocidade. Um conjunto exemplo de feições de interesse previamente conhecidos está representado na figura 9. A figura 9 demonstra a Avenida Beira Mar Norte, na cidade de Florianópolis. Essa avenida é conhecida por ter semáforos equipados com radares, que geram multas quando os veículos ultrapassam o sinal vermelho ou possuem velocidade acima do limite de 80 Km/h. Para que os motoristas não sejam multados, nesses semáforos acontecem desacelerações bruscas frequentemente. Na parte superior da figura 9 está demonstrada a imagem da avenida obtida via satélite. Já na parte inferior da figura 9 estão representadas algumas trajetórias deste conjunto de dados (em cinza) e os semáforos cadastrados, representados pela cor mais escura (preto).



Figura 9. Exemplos de feições de interesse previamente conhecidas.

Para este conjunto de dados foram considerados cinco valores diferentes para os limiares de *minA*, *minD* e *minC* para identificar os movimentos bruscos, demonstrados na tabela 2. Para as acelerações, os limites começam com 3m/s^2 até 7m/s^2 . Já para as desacelerações e mudanças de direção aumentam duas vezes mais (o dobro da aceleração). A desaceleração é um movimento mais brusco do que a aceleração, pois a perda de velocidade de um veículo em alta velocidade acontece muito mais rápido do que o ganho na aceleração. Depois de alguns testes, chegou-se à conclusão de que, para encontrar movimentos bruscos tanto as mudanças de direção (aceleração centrípeta) quanto as desacelerações podem ser duas vezes maiores do que as acelerações. Isso pode ajudar a definir automaticamente esses parâmetros.

Uma área que possui uma anomalia não é considerada um local problemático se de várias trajetórias que por lá passaram, apenas uma apresentou anomalia. Um local problemático somente será causador de problemas se a maioria das trajetórias (mais da metade) que por lá passaram apresentaram uma anomalia compartilhada geograficamente. Dessa maneira, o valor de *minTraj* foi utilizado como 50%, ou seja, locais problemáticos são encontrados somente em áreas que apresentam mais do que 50% das trajetórias que por lá passaram e compartilham geograficamente uma anomalia.

Para cada conjunto de parâmetros (cada coluna na tabela 2) são apresentados o número de trajetórias com anomalias, o número total de anomalias em todas as trajetórias, os níveis de classificação dos motoristas e o número de locais problemáticos encontrados. Pode-se notar que, para os valores de parâmetros menores (Exp1), 53 trajetórias com anomalias foram encontradas com um total de 442 movimentos anômalos. Além disso, foi gerado um alto número de locais problemáticos (79). Ainda no Exp1, 11 motoristas foram classificados como cuidadosos, 39 como distraídos, 9 como perigosos e 5 como muito perigosos. O número de anomalias nas trajetórias diminui à medida que os limiares para movimentos bruscos aumentam. No Exp5, por exemplo, 45 trajetórias apresentaram comportamento anômalo com um total de 62 anomalias e nenhum local foi considerado como local problemático. Para este caso, 19 motoristas foram classificados como cuidadosos, 42 como distraídos e 3 como perigosos. Nenhum motorista foi classificado como muito perigoso.

Tabela 2. Resultados para 5 conjuntos de parâmetros nos experimentos.

Limiares	Exp1	Exp2	Exp3	Exp4	Exp5
<i>minA</i>	3m/s ² ⇔ 10.8Km/h	4m/s ² ⇔ 14.4Km/h	5m/s ² ⇔ 18.0Km/h	6m/s ² ⇔ 21.6Km/h	7m/s ² ⇔ 25.2Km/h
<i>minD</i>	6m/s ² ⇔ 21.6Km/h	8m/s ² ⇔ 28.8Km/h	10m/s ² ⇔ 36.0Km/h	12m/s ² ⇔ 42.2Km/h	14m/s ² ⇔ 50.4Km/h
<i>minC</i>	6m/s ² ⇔ 21.6Km/h	8m/s ² ⇔ 28.8Km/h	10m/s ² ⇔ 36.0Km/h ²	12m/s ² ⇔ 42.2Km/h	14m/s ² ⇔ 50.4Km/h
Resultados					
Trajeto�rias An�malas	53	52	51	46	45
N�mero de Anomalias	442	258	187	91	62
Locais Problem�ticos	79	15	4	1	0
CUIDADOSO	11	12	13	18	19
DISTRA�DO	39	38	37	39	42
PERIGOSO	09	10	11	6	3
MUITO PERIGOSO	05	4	3	1	0

Destaca-se que, com o aumento dos valores dos par metros para medir movimentos bruscos (de Exp1 para Exp5), o n mero de anomalias em trajet rias reduz (de 442 para 62), bem como o n mero de motoristas muito perigosos (de 5 para 0). Como consequ ncia, o n mero de motoristas cuidadosos aumenta (de 11 para 19). Tamb m   alterado o n mero de locais problem ticos, que diminui de 79 para nenhum. Isso

acontece porque quanto maiores os parâmetros para medir os movimentos bruscos, menos movimentos bruscos são encontrados e, conseqüentemente, menos locais problemáticos. Contudo, é importante destacar que, quanto maiores os valores dos parâmetros, menor é o número de movimentos anômalos, mas os movimentos que são descobertos com limites mais elevados são mais relevantes por serem mais bruscos. Por exemplo, os três motoristas perigosos no Exp 5 fazem movimentos bruscos duas vezes maiores do que os 09 motoristas perigosos do Exp1, porque no exp5 os valores dos parâmetros são $minA = 7m/s^2$, $minD = 14m/s^2$ e $minC = 14m/s^2$, enquanto no Exp1, $minA = 3m/s^2$, $minD = 6m/s^2$ e $minC = 6m/s^2$.

A figura 10 mostra parte do conjunto de dados das trajetórias onde os movimentos mais bruscos aconteceram. Na figura 10 (esquerda) é apresentada uma imagem de satélite da área onde as trajetórias foram coletadas. *A*, *B*, e *C* são os lugares onde existiam movimentos bruscos conhecidos *a priori*. *A* é um local com uma feição de interesse (semáforo), *B* é uma curva forte seguida por uma feição de interesse (semáforo) e *C* é uma curva forte. O algoritmo encontra corretamente os movimentos bruscos previamente conhecidos para os três primeiros experimentos da tabela 2 (Exp1, Exp2 e Exp3), com a aceleração variando de $3m/s^2$ a $5m/s^2$ e a desaceleração e a mudança de direção variando de $6m/s^2$ para $10m/s^2$. A figura 10 (2) mostra o resultado para o Exp2, onde a cor mais clara (amarelo) representa as trajetórias que possuem subtrajetórias anômalas, e as cores pretas representam os movimentos bruscos (subtrajetórias anômalas). A figura 10 (3) mostra o resultado para os valores dos parâmetros do Exp3, onde se nota que as anomalias *A*, *B* e *C* ainda são encontradas. O quarto conjunto de valores de parâmetros na tabela 2 (exp4) foi considerado elevado para a busca de anomalias no conjunto de dados do experimento, pois conforme demonstrado na figura 10 (4), as anomalias conhecidas previamente *A* e *B* não foram encontradas.

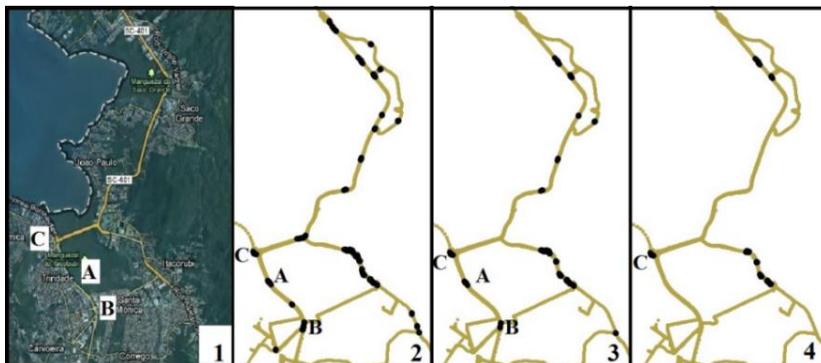


Figura 10. Resultados para três diferentes conjuntos de parâmetros.

Para ilustrar algumas trajetórias anômalas em detalhes, foram selecionadas uma trajetória classificada como perigosa e uma trajetória classificada como muito perigosa. A figura 11 (à esquerda) mostra a área onde as trajetórias ocorreram no mapa. No centro da mesma figura é apresentada a trajetória de um motorista muito perigoso (tid 14) e na direita a trajetória de um motorista perigoso (tid 18), obtidas através do experimento com o conjunto de limites do Exp3. Em amarelo estão todas as trajetórias e em cinza claro as duas trajetórias com anomalias (tid 14 na parte central da figura 11 e tid 18 na parte da direita). Na Figura 11 (centro) e_1 é uma subtrajetória com desaceleração brusca com intersecção com um semáforo (feição de interesse), s_1 é uma desaceleração brusca que inicia em excesso de velocidade. A velocidade do início da anomalia era de 78 km/h onde o limite da via era de 60 Km/h. Em d_1 aconteceram três trocas de faixa sequenciais, caracterizando uma costura. As subtrajetórias r_1, r_2, r_3, r_4 e r_5 foram subtrajetórias com excesso de velocidade, caracterizando que mais da metade da trajetória possui excesso de velocidade. A outra anomalia em u_1 foi uma anomalia sem intersecção com feições de interesse. Dessa maneira, a combinação de anomalias e o excesso de velocidade caracterizaram um motorista muito perigoso para o tid 14.

Na Figura 11 (direita) as subtrajetórias anômalas destacadas em u_2 (vermelho) e u_3 (preto) estavam em lugares sem intersecção com feições de interesse e não ultrapassando o limite de velocidade. Já a subtrajetória anômala r_6 teve excesso de velocidade, porém, mais da metade da trajetória 18 não possui excesso de velocidade. Portanto, a trajetória com tid 18 caracteriza um motorista perigoso. É interessante perceber que a mudança brusca de direção em u_2 (vermelho) foi

consequência da subtrajetória com excesso de velocidade r_6 . O mesmo acontece na Figura 11 (centro) em que a desaceleração brusca s_1 foi uma consequência da subtrajetória em excesso de velocidade r_4 .

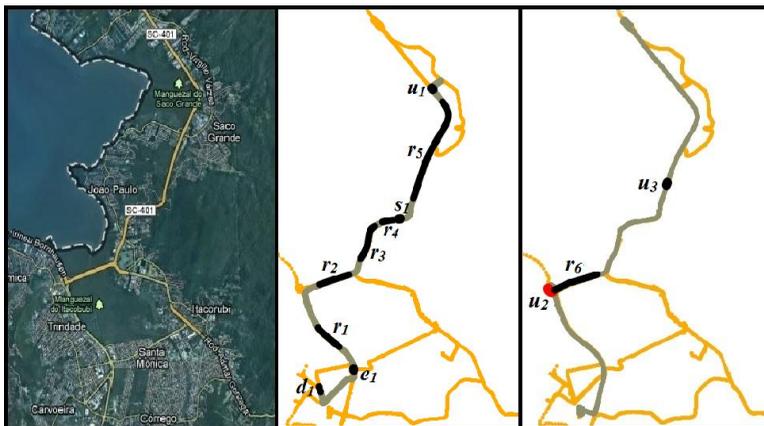


Figura 11. Trajetória Muito Perigosa e Trajetória Perigosa.

No que se refere aos possíveis locais com algum problema que seja o causador das anomalias presentes nas trajetórias, os locais problemáticos são aqueles onde várias trajetórias apresentam movimentos bruscos e não existe intersecção com *feições de interesse* conhecidas previamente e que poderiam ser a razão da anomalia.

Na figura 12 estão demonstrados os locais onde ocorreram dois dos quatro locais problemáticos encontrados utilizando os parâmetros do Exp 3, sendo os dois locais problemáticos com maior número de intersecções de movimentos bruscos. Na parte esquerda da figura 12 estão representados através das imagens obtidas via satélite os dois locais problemáticos, sendo o lado esquerdo superior a região central de Florianópolis onde existe um túnel, e a parte esquerda inferior demonstra parte de uma rodovia que liga a região central ao norte de Florianópolis. Estão representados na figura 12 ao lado direito em cor clara (amarelo) uma aproximação do conjunto total de trajetórias, em cinza as trajetórias que possuem as anomalias compartilhadas (locais problemáticos) que se intersectam nas regiões destacadas em preto denominadas A e B. Nas proximidades de A existem quatro movimentos bruscos, sendo uma desaceleração brusca e três mudanças bruscas de direção. Considerando que existiram 6 trajetórias que passaram pelo mesmo local, um total de 66% das trajetórias que passaram por aquele

local apresentaram anomalia. Já ao lado de *B* existem também quatro movimentos bruscos (quatro desacelerações bruscas), num total de 7 trajetórias que passaram por aquela região. Dessa maneira o local problemático encontrado ao lado de *B* teve 57% das trajetórias apresentando anomalias.

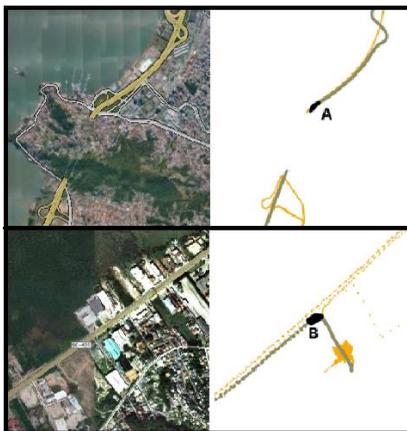


Figura 12. Detalhes de Locais Problemáticos.

4.2 ANÁLISE DE TRAJETÓRIAS DE ONIBUS EM SC

Os dados de veículos de transporte coletivo em SC foram coletados em dois momentos. Em um primeiro momento foi coletado um volume maior de trajetórias de linhas com itinerários distintos onde não existiam feições de interesse previamente conhecidas. Já num segundo momento foi coletado um número menor de trajetórias, porém de linhas que percorriam normalmente o mesmo itinerário onde se conheciam previamente algumas feições de interesse.

4.2.1 Primeira Análise de Trajetórias de Ônibus

O primeiro experimento com trajetórias de transporte coletivo foi realizado com 63 trajetórias coletadas em veículos de transporte público (ônibus), também no estado de Santa Catarina. Os pontos foram coletados com frequência de 1 segundo, durante um período de cinco meses, para diferentes linhas de ônibus e diferentes motoristas.

A busca por movimentos bruscos foi iniciada utilizando os mesmos valores de parâmetros utilizados nos experimentos de veículos

de passeio demonstrados na seção 4.1, porém foi encontrado um reduzido número de anomalias. Considerando que os veículos deste conjunto de dados são maiores e menos ágeis que os automóveis dos experimentos da seção 4.1, os experimentos foram então realizados com limites de movimentos bruscos mais baixos do que os limites utilizados no conjunto de dados de carros de passeio. O mínimo de trajetórias (*minTraj*) apresentando anomalias em uma mesma área geográfica para que um local seja considerado problemático foi utilizado da mesma maneira que nos experimentos de veículos, ou seja, mais do que 50%.

A tabela 3 ilustra os resultados. A variação do limite para aceleração foi de 1 m/s^2 até 4 m/s^2 . Já para desaceleração e mudança de direção, os limites usados foram de 4 m/s^2 até 8 m/s^2 . Na tabela 3 estão demonstrados os limites inferiores (Exp1) e superiores (Exp3). É possível concluir através da tabela 3 que quanto menores os limites, mais anomalias são encontradas da mesma forma como no experimento anterior. A representação visual das anomalias dos três experimentos demonstrados na tabela 3 pode ser visualizada na figura 13 e, assim como na tabela, é possível identificar visualmente que as anomalias encontradas na figura 13 diminuem de *Exp1* para *Exp2* e também de *Exp2* para *Exp3*. Como as anomalias diminuem, consequentemente os locais problemáticos também diminuem.

Tabela 3. Resultados para 3 conjuntos de parâmetros nos experimentos de trajetórias de ônibus.

Limiares	Exp1	Exp2	Exp3
<i>minA</i>	$1_{\text{m/s}^2} \Leftrightarrow 3.6_{\text{Km/h}}$	$2_{\text{m/s}^2} \Leftrightarrow 7.2_{\text{Km/h}}$	$4_{\text{m/s}^2} \Leftrightarrow 14.4_{\text{Km/h}}$
<i>minD</i>	$2_{\text{m/s}^2} \Leftrightarrow 7.2_{\text{Km/h}}$	$4_{\text{m/s}^2} \Leftrightarrow 14.4_{\text{Km/h}}$	$8_{\text{m/s}^2} \Leftrightarrow 28.8_{\text{Km/h}}$
<i>minC</i>	$2_{\text{m/s}^2} \Leftrightarrow 7.2_{\text{Km/h}}$	$4_{\text{m/s}^2} \Leftrightarrow 14.4_{\text{Km/h}}$	$8_{\text{m/s}^2} \Leftrightarrow 28.8_{\text{Km/h}}$
Resultados			
Trajetoórias Anômalas	61	56	39
Número de Anomalias	1130	235	97
Locais Problemáticos	179	26	1
CUIDADOSO	2	7	24
DISTRAÍDO	51	46	29
PERIGOSO	10	10	10
MUITO PERIGOSO	00	00	00

A figura 13 apresenta parte do resultado de três experimentos diferentes (*Exp1*, *Exp2* e *Exp3*), onde parte do conjunto de trajetórias está representada na cor clara (amarelo) e as anomalias encontradas destacadas em preto.

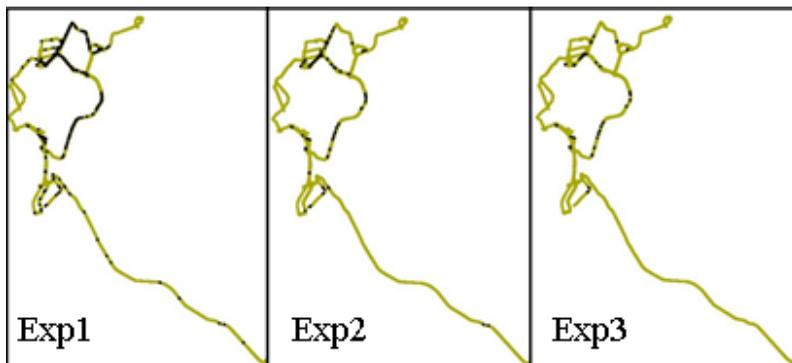


Figura 13. Resultados para três diferentes conjuntos de parâmetros para trajetórias de Ônibus.

Esse conjunto de dados não possui dados referentes às vias percorridas e, dessa maneira, não possuem valores de limites de velocidade das vias. Por esse motivo foi utilizado o limite de 80 Km/h como limite de velocidade, pois o artigo 61 do Código de Trânsito Brasileiro [41] utiliza esse valor como velocidade máxima para Ônibus nas vias urbanas de trânsito rápido. A figura 14 mostra todas as trajetórias em cor mais clara (amarelo) e as anomalias em cor preta, onde em *A* são todas as trajetórias do conjunto de dados. Em *B* (figura 14 – direita) é apresentada uma aproximação da zona onde existe o maior número de anomalias destas trajetórias.

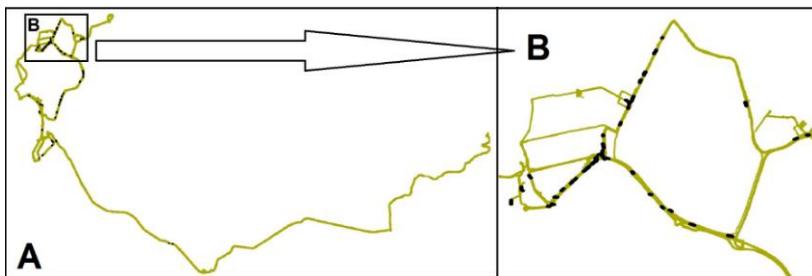


Figura 14. Trajetórias de Ônibus Conjunto 1

Conforme já exposto na tabela 3 (Exp 2), das 63 trajetórias 56 apresentaram comportamento anômalo, com um total de 235 anomalias. Sete delas foram classificadas como cuidadosas, 46 foram classificadas como distraídas e 10 como perigosas. Não foi encontrada nenhuma trajetória com a maior parte do trajeto em excesso de velocidade, considerando o limite de 80Km/h detalhado anteriormente. Também não foram encontradas anomalias de costura entre faixas, que é um comportamento não muito característico para ônibus. Como consequência, não existem trajetórias com comportamento muito perigoso.

Na figura 15 estão demonstradas as trajetórias na cor mais clara e os locais problemáticos em preto, encontrados utilizando os parâmetros do Exp2 da tabela 3. No lado esquerdo da figura 15 estão destacados em preto os movimentos bruscos encontrados como locais problemáticos. Já ao lado direito está destacada a área com mais anomalias próximo à A (área mais problemática).

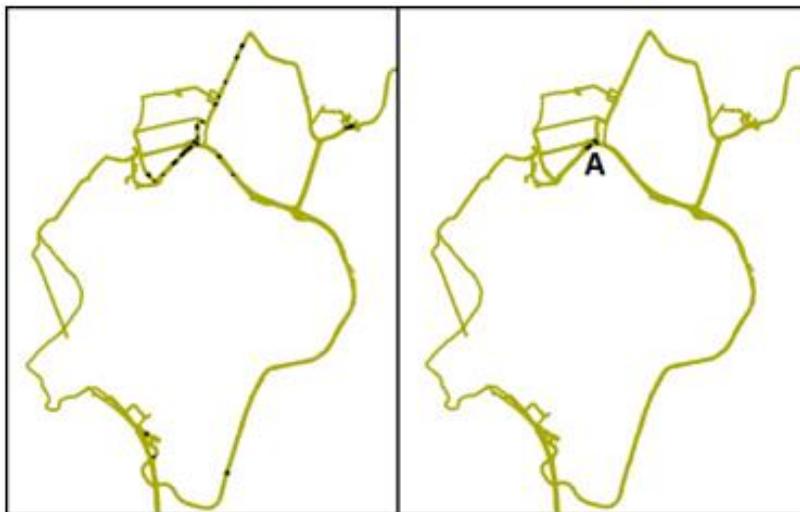


Figura 15. Locais Problemáticos Ônibus Conjunto 1.

A figura 16 representa uma aproximação da região destacada próximo ao A da figura 15. Na figura 16, a região ao lado de A representa a intersecção entre três movimentos bruscos, sendo duas mudanças bruscas de direção e uma desaceleração brusca. Considerando

que passaram 5 trajetórias no local onde foi detectado o local problemático destacado ao lado de *A*, ele possui um percentual de 60% de trajetórias que passaram pelo local e apresentaram a anomalia. Já próximo a região destacada ao lado de *B* passaram 7 trajetórias, sendo que destas, quatro apresentaram movimentos bruscos, sendo três desacelerações bruscas e uma mudança brusca de direção. Dessa maneira, o local problemático próximo à *B* possui uma taxa de 57% das trajetórias com anomalias no local. Ainda analisando a figura 16 é possível identificar que as regiões destacadas próximo às letras *A* e *B* representam locais onde existem cruzamentos de vias, levando a inferir que os motoristas que ali trafegam pratiquem movimentos bruscos.

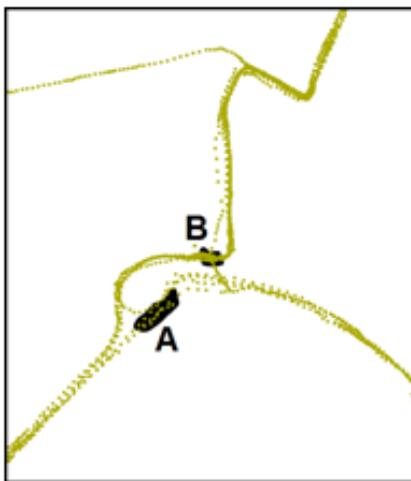


Figura 16. Exemplo de Locais Problemáticos encontrados com trajetórias de Ônibus

4.2.2 Segunda Análise de Trajetórias de Ônibus

A segunda análise de dados de transporte coletivo contém cinco trajetórias coletadas de ônibus, também no estado de Santa Catarina, mais especificamente na cidade de Florianópolis, entre os bairros Trindade e Lagoa da Conceição. As trajetórias foram coletadas durante cinco dias em uma mesma linha de ônibus. Embora este seja um conjunto reduzido de dados e que também seja realizado com dados de Ônibus, este experimento se difere do anterior porque existe o o

conjunto de vias e algumas feições de interesse previamente conhecidas para a região de coleta das trajetórias.

Os experimentos nesse conjunto de dados foram realizados utilizando os mesmos limites utilizados do outro conjunto de dados de transporte coletivo. Os valores de limites foram: $minA = 2 \text{ m/s}^2$ (7,2 Km/h) para aceleração, $minD = 4 \text{ m/s}^2$ (14,4 Km/h) para desaceleração, $minC = 4 \text{ m/s}^2$ (14,4 Km/h) para mudança de direção e $minTraj = 50\%$.

As trajetórias podem ser observadas na figura 17. Existem 5 trajetórias demonstradas na figura 17. A parte superior da figura representa a imagem obtida via satélite e a parte inferior as trajetórias. Na parte inferior da figura 17 e_2 e e_3 são movimentos bruscos (desacelerações) em locais com feições de interesse previamente conhecidas, sendo faixas de pedestres logo à frente de paradas de ônibus. Já u_4 e u_5 são movimentos anômalos onde quatro das cinco trajetórias apresentaram as mesmas anomalias. Como quatro das cinco trajetórias apresentaram anomalias próximas à u_4 e u_5 , ambos os locais foram identificados como locais problemáticos. Esses locais problemáticos foram gerados da descoberta de mudanças bruscas de direção ou desacelerações bruscas nas regiões.

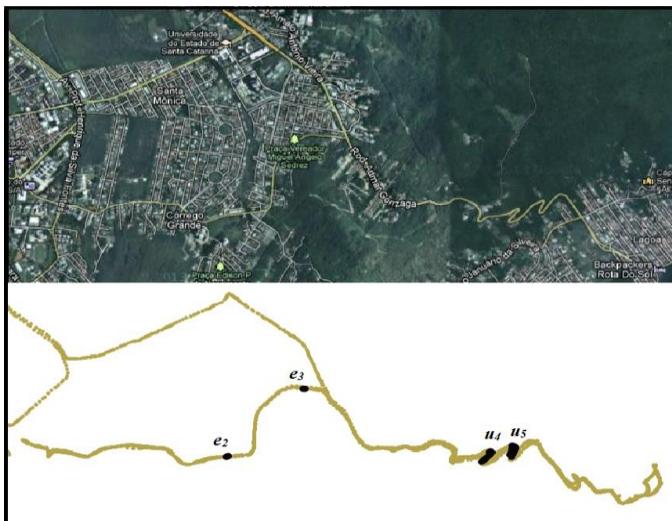


Figura 17. Trajetórias de Ônibus

Desse conjunto de trajetórias, todas apresentaram movimentos bruscos e foram classificadas como *distraídas*, pois as anomalias

aconteceram sempre em locais com feições de interesse previamente conhecidos ou em locais onde outras trajetórias apresentaram também. Não foram encontradas costuras nem tampouco trajetórias com excesso de velocidade nesse conjunto de dados. O resultado com a classificação das cinco trajetórias desse conjunto de dados está demonstrado na tabela 4.

Tabela 4. Classificação dos Motoristas para Trajetórias de Ônibus.

MEDIDAS	TOTAIS
Trajeto�rias An�malas	05
N�mero de Anomalias	10
Locais Problem�ticos	02
LEVEL 1 - CUIDADOSO	00
LEVEL 2 - DISTRA�DO	05
LEVEL 3 - PERIGOSO	00
LEVEL 4 – MUITO PERIGOSO	00

5 CONCLUSÃO E TRABALHOS FUTUROS

A geração de dados de trajetórias de veículos vem crescendo em razão do crescente aumento do número de veículos equipados com dispositivos de coleta de dados. A análise do comportamento dessas trajetórias está se tornando muito útil em vários domínios de aplicação, inclusive na análise de acidentes de trânsito que estão diretamente relacionados à reação e ao comportamento dos motoristas. O comportamento dos motoristas pode afetar não só o tráfego, mas os pedestres que cruzam a rua, os passageiros em um ônibus ou táxi, e até mesmo gerar danos no transporte de produtos delicados, como frutas e legumes.

Alguns trabalhos existentes analisam características de motoristas, mas não usando dados de GPS e nem para classificar os motoristas em diferentes níveis de periculosidade. Ferramentas comerciais, em geral, avaliam o motorista e geram índices de qualidade na condução de veículos baseando-se em movimentos individuais, mas não comparam um comportamento a outras trajetórias ou a feições de interesse que possam ser causadoras do comportamento anômalo, como proposto neste trabalho.

Nesta dissertação foi apresentado um algoritmo de dois passos para medir o comportamento dos motoristas. Primeiro, o algoritmo encontra movimentos bruscos (acelerações bruscas, desacelerações bruscas, mudanças bruscas de direção), costuras entre faixas e excesso de velocidade. Em seguida, de acordo com as diferentes características relacionadas aos movimentos bruscos como anomalias repetitivas, feições de interesse e velocidade das trajetórias, os motoristas são classificados em níveis de periculosidade. Na segunda parte do algoritmo também são encontrados e destacados locais que podem ser causadores de anomalias com base em anomalias frequentes.

Os experimentos foram realizados com dados reais de trajetórias de carros e trajetórias de ônibus, onde parte dos movimentos anômalos eram previamente conhecidos para encontrar bons limites dos parâmetros utilizados nas análises. Para veículos de passeio os melhores valores limites para aceleração, desaceleração e mudança brusca de direção foram 5m/s^2 , 10m/s^2 e 10m/s^2 respectivamente. Com as anomalias encontradas o algoritmo classificou as trajetórias em um dos níveis de periculosidade definidos. Ainda, foram encontrados locais problemáticos com anomalias frequentes.

Atualmente já existem dados de trajetórias de caminhões de empresas de transporte de mercadorias para este estudo, porém esses

dados foram coletados em intervalos de 30 segundos. Como movimentos bruscos acontecem rapidamente, esses dados só poderiam ser utilizados se fossem interpolados. Por esse motivo, em relação aos trabalhos futuros pretende-se obter mais dados de trajetórias de grandes empresas com intervalos de coleta de 1 segundo para analisar o comportamento dos motoristas e comparar com um *feedback* obtido na empresa em relação aos seus motoristas. Com esses novos experimentos objetiva-se também avaliar outras características dos movimentos e definir os valores dos parâmetros de limites utilizando o conhecimento de especialistas na área de transportes.

O resultado parcial deste trabalho foi publicado em “Inferring Drivers Behavior through Trajectory Analysis”, IEEE Conf. on Intelligent Systems. [40].

REFERÊNCIAS

1. Lommel, E. (1900) “Experimental physics”, K. Paul, Trench, Trübner & Co., p. 63.
2. Pentland, A., Liu, A. (1999) “Modeling and prediction of human behavior”, *Neural Computation* 11, p.229–242.
3. Rigolli, M., Williams, Q., Gooding, M. J., Brady, M. (2005) “Driver behavioural classification from trajectory data”, *(ITS) Intelligent Transportation Systems* 6, p. 889-894.
4. Sathyanarayana, A., Boyraz, P., Hansen, J. H. L. (2008) “Driver Behavior Analysis and Route Recognition by Hidden Markov Models”, *Proceedings of the 2008 IEEE International Conference on Vehicular Electronics and Safety (ICVES 2008)*.
5. Imamura, T., Yamashita, H.; Othman, MD bin R., Zhang, Z., Miyake, T. (2008) “Driving behavior classification river sensing based on vehicle steering wheel operations”, *SICE Annual Conference*, p. 2714 – 2718.
6. Inata, K., Raksincharoensak, P., Nagai, M. (2008) “Driver behavior modeling based on database of personal mobility driving in urban area,” in *Proc. Int. Conf. Control, Autom. Syst.*, p. 2902–2907.
7. Quintero, M. C. G., López, J. A. O., Rúa, J. M. P. (2010) “Intelligent erratic driving diagnosis based on artificial neural networks” *ANDESCON, 2010 IEEE*, p.1 – 6.
8. Gindele, T., Brechtel, S., Dillmann, R. (2010) “A Probabilistic Model for Estimating Driver Behaviors and Vehicle Trajectories in Traffic Environments”, *IEEE ITSC (Conference on Intelligent Transportation Systems)*, p.1625–1631.
9. Liao, Z., Yu, Y., Chen, B. (2010) “Anomaly detection in GPS data based on visual analytics,” in *Proc. IEEE Symp. Visual Anal. Sci. Technol.*, p. 51–58.
10. Zhang, D., Li, N., Z hou, Z.-H., Chen, C., Sun, L., Li, S. (2011) “iBAT: detecting anomalous taxi trajectories from GPS traces”, *Proceedings ACM UbiComp*.
11. Carboni, E. M., Bogorny, V. (2011) “Identificando comportamentos anômalos em trajetórias de objetos móveis”, *XII GEOINFO*, p. 141-146.

12. Verroios, V., Vicente, C. M., Delis, A. (2012) “Alerting for vehicles demonstrating hazardous driving behavior”, *MobiDE 2012*, p. 15-22.
13. Quintero M, C.G., Lopez, J. O., Pinilla, A.C.C. (2012) “Driver behavior classification model based on an intelligent driving diagnosis system”, *Intelligent Transportation Systems (ITSC), 2012 15th International IEEE Conference*, p. 894 - 899.
14. Alvares, L.O., Bogorny, V., Kuijpers, B., Macedo, J.A.F., Moelans, B. (2007) “A model for enriching trajectories with semantic geographical information”, In *GIS'07: Proceedings of the 15th Annual ACM International Symposium on Advances in Geographic Information Systems*, New York, NY, USA, 2007. ACM Press.
15. Palma, A.T., Bogorny, V. Alvares, L.O. (2008) “A Clustering-based approach for discovering interesting places in trajectories”, *SAC*, p. 863-868.
16. Baglioni, M., de Macêdo, J. A. F., Renso, C., Trasarti, R., Wachowicz, M. (2009) “Towards Semantic Interpretation of Movement Behavior”, *AGILE Conference*, p. 271-288.
17. Open Gis Consortium – OGC – Making location count. Disponível em 2014: <http://www.opengeospatial.org/>.
18. Wen, J., Li, C., Xiong, Z. (2011) “Behavior pattern extraction by trajectory analysis”, *Frontiers of Computer Science in China* 5(1), p. 37-44.
19. Janeja, V. P., Atluri, V., Adam, N. R. (2004) “Detecting Anomalous Geospatial Trajectories through Spatial Characterization and Spatio-Semantic Associations”, *DG.O 2004*.
20. Laube, P., Imfeld, S. (2002) “Analyzing Relative Motion within Groups of Trackable Moving Point Objects”, *GIScience 2002*, p. 132-144.
21. Dodge, S., Weibel, R., Laube, P. (2009) “Exploring movement-similarity analysis of moving objects”, *SIGSPATIAL Special* 1(3), p. 11-16.
22. Cao, H., Mamoulis, N., Cheung, D. W.: “Mining Frequent Spatio-Temporal Sequential Patterns.” *ICDM 2005*: 82-89.

23. Cao, H., Mamoulis, N., Cheung, D. W.: "DiscoMUITO of Periodic Patterns in Spatiotemporal Sequences." *IEEE Trans. Knowl. Data Eng.* 19(4): 453-467 (2007).
24. Alvares, L. O., Loy, A. M., Renso, C., Bogorny, V. (2011) "An algorithm to identify avoidance behavior in moving object trajectories", *Journal of the Brazilian Computer Society* 17(3), p. 193-203.
25. Rocha, J. A. M. R., Times, V. C., Oliveira, G., Alvares, L. O., Bogorny, V. (2010) "DB-SMoT: A Direction-based spatio-temporal clustering method", *Fifth IEEE International Conference on Intelligent Systems*, p. 114-119.
26. Siqueira, F. L., Bogorny, V. (2011) "Discovering Chasing Behavior in Moving Object Trajectories", *T. GIS* 15(5), p. 667-688.
27. Trasarti, R., Pinelli, F., Nanni, M., Giannotti, F. (2012) "Individual Mobility Profiles: Methods and Application on Vehicle Sharing", *SEBD*, p. 35-42.
28. Trasarti, R., Pinelli, F., Nanni, M., Giannotti, F. (2011) "Mining mobility user profiles for car pooling", *KDD*, p. 1190-1198.
29. Di Lorenzo, G., Pinelli, F., Pereira, F. C., Biderman, A. Ratti, C., Lee, C., Lee, C. (2009) "An Affective Intelligent Driving Agent: Driver's Trajectory and Activities Prediction", *70th IEEE VTC Fall*, p. 1-4.
30. WHO - World Health Organization, "Global status report on road safety 2013" (2013), [Online], Disponível em 2013: http://www.who.int/entity/violence_injury_prevention/road_safety_status/2013/en/index.html
31. Accident And Traffic Rules & Regulation, "Top 25 Causes of Car Accidents" (2012), [Online], Disponível em 2013: <http://accidentviews.wordpress.com/2012/02/14/top-25-causes-of-car-accidents/>
32. AA Car Insurance. Disponível em 2014: <http://www.theaa.com/insurance/car-insurance.jsp>
33. Siqueira, F. L. (2012) "Identificação de comportamentos de perseguição em trajetórias de objetos móveis", *Dissertação de Mestrado em Ciências da Computação – UFSC*, Disponível em:

<https://repositorio.ufsc.br/bitstream/handle/123456789/99253/305188.pdf?sequence=1>

34. Gianotti, F., Pedeschi, D. (2008) “Mobility, Data Mining and Privacy”, [S.l.]: Springer
35. Quantum GIS Development Team (2014). Quantum GIS Geographic Information System, Disponível em: <http://qgis.osgeo.org>
36. Postgis Development Team (2014). Postgis Spatial and Geographic objects for PostgreSQL, Disponível em: <http://postgis.net/development>
37. Postgres Development Team (2014). Postgres: The world’s most advanced open source database. Disponível em: <http://www.postgresql.org/developer/>
38. NetBeans Development Team (2014). The NetBeans Platform is a generic framework for Swing applications, Disponível em: <http://wiki.netbeans.org/Development>
39. Google Inc. Google Earth (2014). Disponível em: <://www.google.com.br/intl/pt-BR/earth/index.html>
40. Carboni, E. M., Bogorny, V. (2014) “Inferring Drivers Behavior through Trajectory Analysis”, IEEE Conf. on Intelligent Systems (1) 2014, p. 837-848
41. Departamento Nacional de Trânsito – Código de Transito Brasileiro (2014). Disponível em: <http://www.denatran.gov.br/ctb.htm>
42. Fontes, V. C., Alencar, L. A., Renso, C., Bogorny, V. (2013) “Discovering Trajectory Outliers between Regions of Interest”, GeoInfo 2013, p. 49-60
43. Aquino, A. R., Alvares, L. O., Renso, C., Bogorny, V. (2013) “Towards Semantic Trajectory Outlier Detection”, GeoInfo 2013, p. 115-126
44. Braz, F., J., Bogorny, V. (2012) “Introdução a Trajetórias de Objetos Móveis: conceitos, armazenamento e análise de dados”, Editora Univille. 2012, 116 paginas.