



UNIVERSIDADE FEDERAL
DO RIO DE JANEIRO




Imputação de Dados Anômalos e Cálculo de Parâmetros de Tráfego PNCT

*Fabio Ramos
Heudson Mirandola
Glaydston Ribeiro
Saul Quadros*

14 de Junho de 2016


Brasília - DF

Volume de um dia típico do Equipamento 193 – Sentido C




Volume de um dia anômalo do Equipamento 243 – Sentido C

Contagem de Veículos




Um exemplo de um dia com dados ausentes. (gerado artificialmente)



O que esperamos da reconstrução?

Que seja precisa e respeite a variabilidade natural dos dados.

(Um método baseado em testes)



Por que tratar os dados ?

SURVEY - SUPPLY CHAIN, TRANSPORTATION & LOGISTICS – MITx (1003 participantes)

Baseado na sua experiência em gerenciar grandes projetos, de onde surgiam os maiores problemas?

1- Escopo do projeto mudava todo tempo.	40%
2- <u>Os dados eram incompletos/incorretos/falhos, etc..</u>	23%
3- As expectativas em relação ao projeto continuavam mudando.	20%
4- A definição da cadeia logística não era clara desde o começo.	10%
5- Outros	5%
6- Os modelos matemáticos não eram adequados.	1%



Por que tratar os dados ?

- Permite o uso de métodos de inferência para dados completos (e.g. VMD, VMDA, Médias, Medianas, etc..).
- Permite o uso de dados disponíveis ao coletor de dados mas não disponíveis ao usuário final. (BIG DATA)
- O problema dos dados anômalos (e.g. ausentes) é resolvido de uma vez por todas. A imputação na origem unifica estudos posteriores, evitando confusão na análise de dados e reduzindo custos desnecessários

OBJETIVO

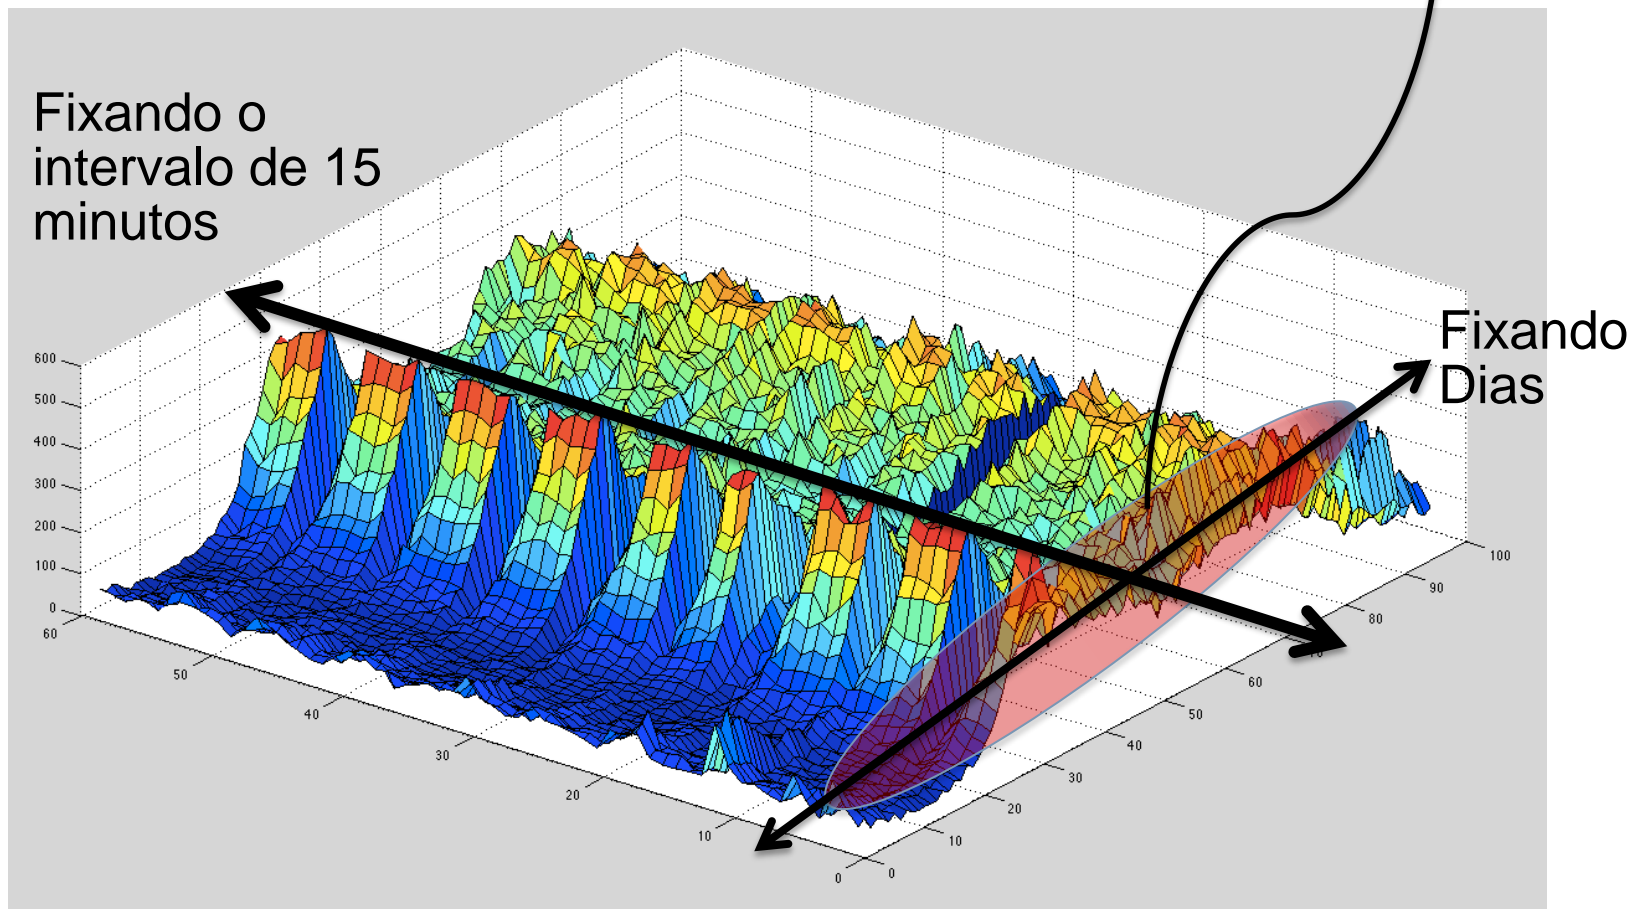
Substituição **eficiente** dos dados anômalos por vários valores prováveis, de maneira que a **variabilidade natural** dos dados seja fielmente representada na reconstrução.



Visualizando os dados de tráfego

$$\vec{d}_i = \left(t_1^{(i)}, t_2^{(i)}, \dots, t_{28}^{(i)}, \dots, t_{96}^{(i)} \right)$$

Cada dia é representado por um vetor de 96 entradas, onde cada uma representa um intervalo de 15 minutos.



BR-116 Km 292




UNIVERSIDADE FEDERAL
DO RIO DE JANEIRO



Ministério dos
Transportes

Exemplo 1

- Dado ausente de 1 dia
- Contagem: 15 min
- BR-116, Km 292




MAPA DE CONTAGEM

A ideia é reconhecer dias parecidos com o que se sabe do dia discrepante e usa-los para a reconstrução!

Dado discrepante

Fixando o dia

TEMPO (15 min)



Fixando o intervalo de 15 min
Dias variados

DIAS




UNIVERSIDADE FEDERAL DO RIO DE JANEIRO



Ministério dos Transportes

BUSCA POR DIAS PARECIDOS

Dia com dados ausentes




UNIVERSIDADE FEDERAL DO RIO DE JANEIRO




BR-408, KM 102

Jan-Out/2015



Aprendizado de Máquinas e Reconhecimento de Padrões




A Maldição da Dimensionalidade

Comparar dias é equivalente a comparar vetores em \mathbb{R}^{96}


$$\vec{d}_i = \left(t_1^{(i)}, t_2^{(i)}, \dots, t_{28}^{(i)}, \dots, t_{96}^{(i)} \right)$$

$$\vec{d}_j = \left(t_1^{(j)}, t_2^{(j)}, \dots, t_{28}^{(j)}, \dots, t_{96}^{(j)} \right)$$


1-D: 42% of data captured.



2-D: 14% of data captured.




3-D: 7% of data captured.




4-D: 3% of data captured.


t = 0




a) 1D - 4 regions



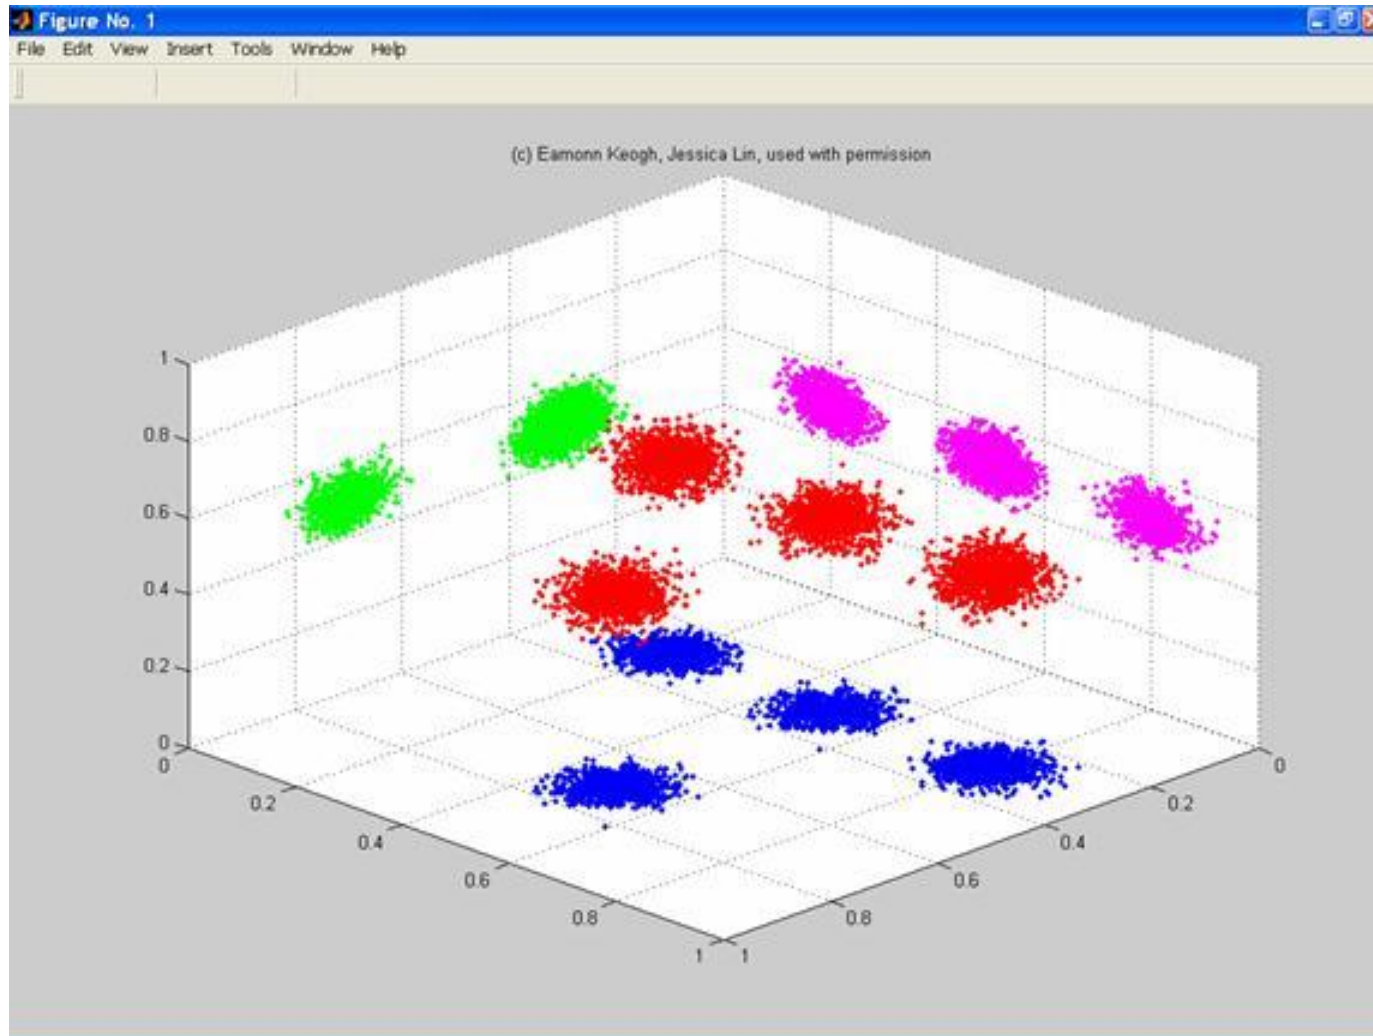
b) 2D - 16 regions



c) 3D - 64 regions



O Perigo da redução da dimensionalidade






BUSCA E SUBSTITUIÇÃO POR DIAS PARECIDOS

Uma tarefa simples de formular, mas difícil de executar.

- Buscar dias com médias/medianas parecidas
- Usar mesmos dias da semana (**sem verificar periodicidade**).
- Regressões Lineares
- Métodos de Bootstrap sem aprendizado a priori
- K-NN sem aprendizado a priori

Ideias
Ruins



O arsenal

Técnicas Clássicas de Estatística e Técnicas Recentes de Machine Learning

- Non-Normal Bayesian Imputation
- K-Nearest Neighbors
- Soft K-means Clusterization
- Approximate Bayesian Bootstrap
- Unbiased Intra-Inter Cluster distances
- P-Select Similarity Ratio
- Gaussian Process (Previsão de Tráfego Futuro) – Em desenvolvimento avançado.



A ESTRATÉGIA

- Procure classes de dias (Clusterização K-Means que supere a maldição da dimensionalidade).
- Ache dias próximos dentro das classes (K-NN qualificado).
- Sorteio não enviesado dos dias próximos da mesma classe. (Bootstrap).



Tudo deve ser feito o mais simples possível, mas não mais simples do que isso. - Einstein

A NATUREZA INTERMITENTE E DE ALTA VARIABILIDADE DOS
DIFERENTES EQUIPAMENTOS ANALISADOS
TORNAM TODOS OS MÉTODOS SIMPLES DE REGRESSÃO
“SOLUÇÕES” SIMPLES DEMAIS!



Comparando dias

O desafio é separar os dias em classes,
mas não criar classes demais



Clusterização

Algoritmo K-Médias

1 - Distribua K pontos

2 - Calcule vizinhanças locais dos K pontos


+ versões

sofisticadas


3 - Tome as médias como os novos K pontos,

4- Se os clusters estão bem definidos, pare.

Do contrário, retorne ao passo 2.




Recalculating the centroids



Exit of k-means algorithm





Definindo um Cluster: Razão INTRA/INTER



$$Intra = \sum_{(X_i, X_j) \in P} \frac{dist(X_i, X_j)}{|P|}$$

$$Inter = \sum_{(X_i, X_j) \in Q} \frac{dist(X_i, X_j)}{|Q|}$$




$$R = Intra / Inter \ll 1$$



Razão de Similaridade P-Select


(Superando a maldição da dimensionalidade)

$$PSelect(X, Y, K_d) = \left[\sum_{i \in S(X, Y)} \left(1 - \frac{|x - y|}{m_i - n_i} \right)^p \right]^{1/p}$$





Identificando a classe correta

Conjunto dos dias semelhantes ao dia com gap baseado na vizinhança do evento.



Dados clusterizados

Agora, sorteamos à partir dos K-NN dentro do cluster.



Como fazer os sorteios? *Non-Normal Bayesian Imputation*

Input: Valores Observados (Y_1, \dots, Y_n)

Output: M valores Imputados



Passo 1: Sorteie $(n-1)$ números aleatórios no intervalo $(0, 1)$ e seja (a_1, \dots, a_{n-1}) essa sequência ordenada. E sejam $a_0 = 0, a_n = 1$.

Passo 2: Sorteie cada um dos valores M valores faltantes escolhendo de (Y_1, \dots, Y_n) com probabilidades $(a_1 - a_0), (a_2 - a_1), \dots, (1 - a_{n-1})$.




APLICANDO A ESTRATÉGIA!


Exemplo 1

- Dado ausente de 1 dia
- Contagem: 15 min
- BR-116, Km 292

- Procure classes de dias
- Ache dias próximos dentro das classes.
- Sorteio (Bootstrap).



BR-116, KM 292 Abril-Maio/2015



UNIVERSIDADE FEDERAL
DO RIO DE JANEIRO




COPPE
FUNDAÇÃO
UFRJ

Instituto Alberto Luis Coimbra de
Pós-Graduação e Pesquisa em Engenharia


COPPETEC
FUNDAÇÃO

Ministério dos
Transportes
GOVERNO FEDERAL
BRASIL
PAÍS RICO E PAÍS SEM POBREZA

O Resultado Final



BR-116 KM-292 04-05/2015
Missing - 08/04/2015



UNIVERSIDADE FEDERAL DO RIO DE JANEIRO




COPPE UFRJ

COPPETEC FUNDAÇÃO

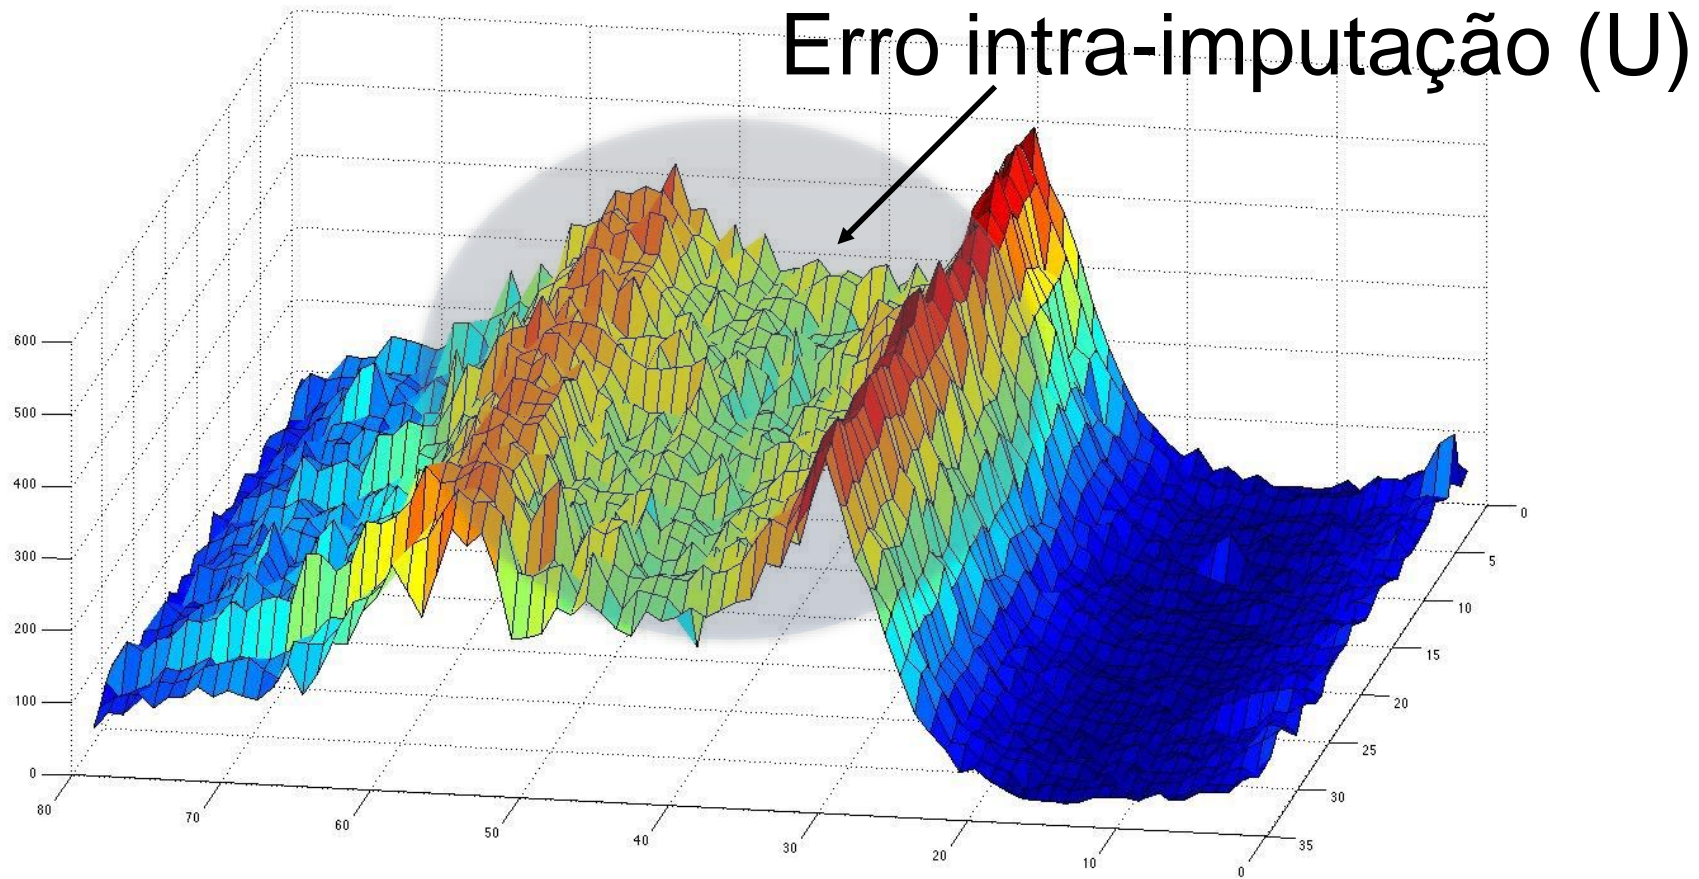


BRASIL PAÍS RICO É PAÍS SEM POBREZA

Ministério dos Transportes



BR-116, KM 292
Abril-Maio/2015



UNIVERSIDADE FEDERAL
DO RIO DE JANEIRO




COPPE
FUNDAÇÃO
UFRJ

Instituto Alberto Luis Coimbra de
Pós-Graduação e Pesquisa em Engenharia

COPPETEC
FUNDAÇÃO

GOVERNO FEDERAL
BRASIL
PAÍS RICO E PAÍS SEM POBREZA

Ministério dos
Transportes




Um segundo filtro de Outliers

- FILTROS MAD (Median Absolute Deviation)
Condicionados e com Médias móveis

$$MAD = \text{mediana}(|X_i - \text{mediana}(X_i)|)$$

- FILTROS de Densidade (Soft Clusters)




Testes de Confiança

Testes com dados do PNCT (2014-2015) mostram, até o momento, baixos erros médios relativos em valor absoluto.

(Para estradas de movimento não-trivial.)


$$\frac{1}{\#R} \sum_{(i,j) \in R} \frac{|Reconst(i,j) - Real(i,j)|}{|Real(i,j)|} \sim 2\% - 10\%$$



Testes de Confiança

Testes com dados do PNCT (2014-2015) mostram, até o momento, ainda mais baixos erros médios relativos. (Para estradas de movimento não-trivial.)

$$\frac{1}{\#R} \sum_{(i,j) \in R} \frac{Reconst(i,j) - Real(i,j)}{Real(i,j)} \sim 0.1\% - 3\%$$



TRABALHO EM ADAMENTO

RECLASSIFICAÇÃO DA CLASSE J “OUTROS”






DADOS CATEGÓRICOS



TRABALHO EM ADAMENTO

RECLASSIFICAÇÃO DA CLASSE J “OUTROS”





Proper Hot-Deck

ALGORITMO ABB – APPROXIMATE BAYESIAN BOOTSTRAP (RUBIN)

r candidatos íntegros, m dados anômalos

- 1- Selecione r unidades com reposição dos r candidatos íntegros para formar o conjunto doador.
- 2- Selecione m unidades com reposição do conjunto doador.





ALGORITMO ABB – APPROXIMATE BAYESIAN BOOTSTRAP (RUBIN)

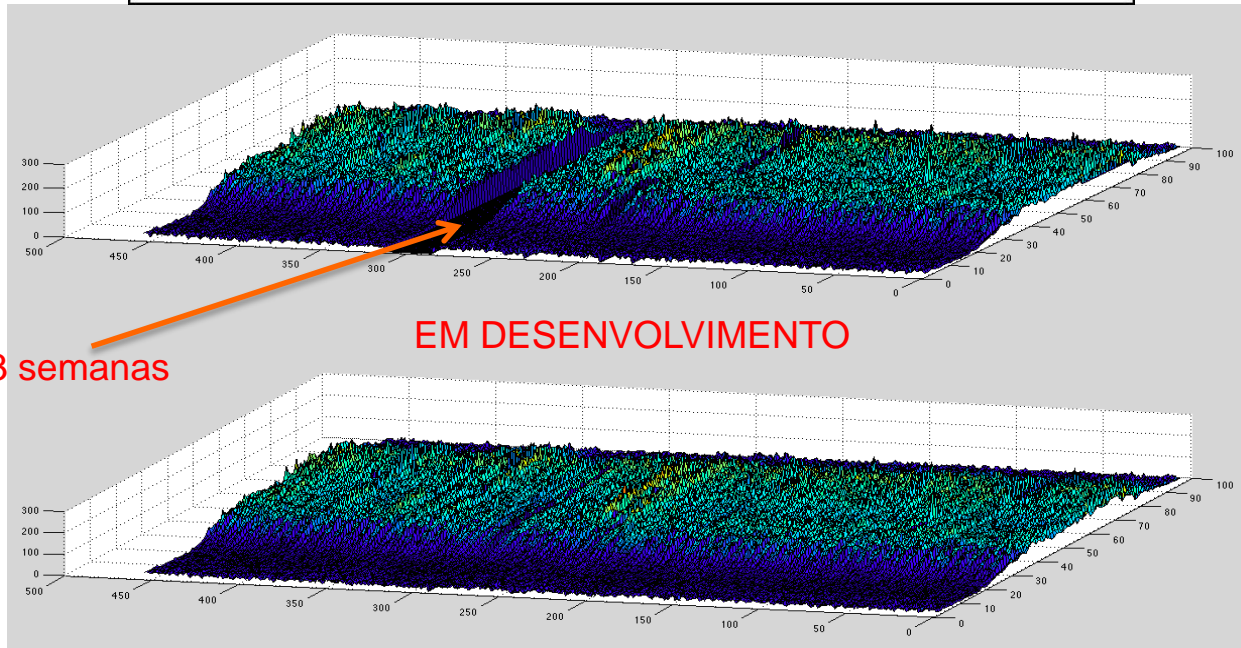

r candidatos íntegros, m dados anômalos

Testes preliminares com 5 equipamentos mostram eficácia uniforme em torno de **80% (INACEITÁVEL ?)**

NOTA: Em uma situação com 30% de dados anômalos (**inaceitável**), uma imputação com 80% de eficiência leva a um erro total de apenas 6% (**aceitável**).



ENTRE A RECONSTRUÇÃO E A PREVISÃO



GAUSSIAN PROCESSES E ESTIMATIVAS (EM DESENVOLVIMENTO)

Grupo de Matemática Aplicada ao Aprendizado de Máquinas e Previsões

Prof. FABIO RAMOS - UFRJ





Prof. HEUDSON MIRANDOLA - UFRJ

DOUGLAS PICCIANI - UFRJ


IVANI IVANOVA – UFRJ

CLAUDIO VERDUN- UFRJ

Dr. STEFAN ZOHREN (OXFORD UNIVERSITY)




GAUSSIAN PROCESSES E PREVISÃO (EM DESENVOLVIMENTO)




$$p(\mathbf{y}(\mathbf{x})) = \mathcal{N}(\boldsymbol{\mu}(\mathbf{x}), \mathbf{K}(\mathbf{x}, \mathbf{x}))$$

$$\mathbf{K}(\mathbf{x}, \mathbf{x}) = \begin{pmatrix} k(x_1, x_1) & k(x_1, x_2) & \cdots & k(x_1, x_n) \\ k(x_2, x_1) & k(x_2, x_2) & \cdots & k(x_2, x_n) \\ \vdots & \vdots & \ddots & \vdots \\ k(x_n, x_1) & k(x_n, x_2) & \cdots & k(x_n, x_n) \end{pmatrix}$$



GAUSSIAN PROCESSES E PREVISÃO (EM DESENVOLVIMENTO)

PREVISÃO DE 20 DIAS



Início do processo



Pre-análise dos dados

- Quais problemas a tratar?
- Como minerar esses dados?
- Tempo para se obter resultados.

No início, foram muitas reuniões:



Outlier - Ausencias de eventos

eq	sent	fx	dt_inic	dt_fin	hrs_gap
274	C	611	2015-07-08 01:39:29.160	2015-07-08 01:57:18.617	0.29707138888888889
274	C	611	2015-07-08 02:49:08.523	2015-07-08 03:05:53.627	0.27919555555555553
274	C	611	2015-07-08 03:05:53.627	2015-07-08 03:28:02.970	0.36926194444444443
274	C	611	2015-07-08 03:28:02.970	2015-07-08 03:47:39.697	0.3268686111111111
274	C	611	2015-07-08 04:17:26.933	2015-07-08 04:53:29.460	0.60070194444444445
274	C	611	2015-07-08 17:02:49.397	2016-02-15 11:12:16.000	5322.157389722222
274	C	611	2016-02-15 14:26:39.000	2016-02-15 15:33:20.000	1.1113888888888889
274	C	611	2016-02-15 16:31:40.000	2016-02-15 17:17:26.000	0.7627777777777778
274	C	611	2016-02-15 19:20:13.000	2016-02-15 20:26:20.000	1.1019444444444444
274	C	611	2016-02-15 22:03:43.000	2016-02-15 23:08:39.000	1.0822222222222222
274	C	611	2016-02-16 00:44:47.000	2016-02-16 01:50:03.000	1.0877777777777777


Vazio de eventos de mais de 5 meses



Exemplo 1


- Dado ausente de 1 dia
- Contagem: 15 min
- BR-116, Km 292

Marcador de Outliers



Dia Discrepante





Outliers na classificação

1 - Categoria Outros

Categoria J = Motocicletas

2 - Classificação inconsistente





```
df_desc_J=df.loc[df['sg_veic']=='J'].describe()
df_desc_J
```

	eq	br	km	fx	id_tp_veic	id_categ	id_cl_macro	id_cl_convide	veloc	ptb	tam_tot
count	10420	10420	10420	10420.000000	10420	10420	10420	10420	10420.000000	10420.000000	10420.000000
mean	209	290	702	1.537332	77	2	10	9	91.674856	363.546065	1.042131
std	0	0	0	0.498628	0	0	0	0	24.187772	822.287901	0.649592
min	209	290	702	1.000000	77	2	10	9	3.000000	60.000000	0.000000
25%	209	290	702	1.000000	77	2	10	9	75.000000	180.000000	1.000000
50%	209	290	702	2.000000	77	2	10	9	90.000000	260.000000	1.000000
75%	209	290	702	2.000000	77	2	10	9	106.000000	380.000000	1.000000
max	209	290	702	2.000000	77	2	10	9	199.000000	24600.000000	23.000000

Motocicleta com peso bruto total de 24 toneladas?




Qual é o tamanho das ausências?



50% dos equipamentos apresentaram outliers nos eventos (ausências e repetições) em pelo menos 10% dos eventos



Outliers na classificação



90% dos equipamentos (contando os sentidos) apresentam baixo índice (<5%) de 'outros'



O que estamos entregando?

Versão 0.9

- Algoritmo de identificação de dados anômalos
- Base de dados tratados
(Sem a reclassificação da classe L “OUTROS”)
- VMDs - por ano, mês e semana de cada equipamento (por sentido).
- Horas-picos e volumes-picos (por ano mês e semana) por equipamento e sentido




	eq	sent	fx	dt_inic	dt_fin	hrs_gap
0	174	D	1	2014-04-20 01:59:55	2014-04-20 02:18:11	0.30444444444444446
82	174	D	1	2014-11-30 08:41:39	2014-11-30 08:59:47	0.3022222222222222
83	174	D	1	2014-11-30 09:33:54	2014-11-30 09:52:44	0.3138888888888889
84	174	D	1	2014-11-30 09:52:50	2014-11-30 10:25:18	0.5411111111111111
85	174	D	1	2014-11-30 11:25:33	2014-11-30 11:40:57	0.25666666666666665
86	174	D	1	2014-11-30 21:06:09	2014-11-30 21:47:55	0.6961111111111111
87	174	D	1	2014-11-30 21:47:55	2014-12-01 06:41:45	8.897222222222222
88	174	D	1	2014-12-01 06:41:45	2014-12-01 08:58:05	2.272222222222222
89	174	D	1	2014-12-01 08:58:22	2014-12-01 09:21:32	0.3861111111111111
90	174	D	1	2014-12-01 19:04:15	2014-12-02 11:53:46	16.825277777777778
91	174	D	1	2014-12-02 12:02:13	2014-12-02 12:31:58	0.49583333333333335
92	174	D	1	2014-12-02 13:12:37	2014-12-02 13:36:18	0.3947222222222222
93	174	D	1	2014-12-02 13:43:57	2014-12-03 10:43:33	20.993333333333332
94	174	D	1	2014-12-04 20:05:09	2014-12-04 20:22:18	0.28583333333333333

16 Horas de vazio



eq	sent	fx	dt_oc	rep
183	D	1	2014-05-22 06:27:25	4
183	D	1	2015-01-18 22:47:25	4
183	D	1	2015-01-20 00:35:42	8
183	D	1	2015-01-23 11:02:32	17
183	D	1	2015-01-26 14:39:45	52
183	D	1	2015-04-02 20:16:49	88
183	D	1	2015-04-08 17:45:09	20
183	D	1	2015-04-17 19:59:59	14
183	D	1	2015-04-20 08:37:39	37
183	D	1	2015-04-29 14:53:49	10
183	D	1	2015-04-30 00:32:49	28
183	D	1	2015-05-01 09:16:55	39
183	D	1	2015-05-03 14:59:59	10
183	D	1	2015-07-12 22:00:00	10439
183	D	1	2015-07-12 23:00:00	51892
183	D	1	2015-07-13 00:00:00	4079
183	C	2	2015-01-18 22:47:25	6
183	C	2	2015-01-20 00:35:42	7
183	C	2	2015-01-23 11:02:32	10

Relatórios de repetições simultaneas na faixa



Informações da Hora Pico (geral e por categorias)

	dia_inic	dia_fin	dias_validos	dia_hr_pico	vol_pico	vol_dia_pico	per_dia_pico	vmd_ano
ano_2015_sent_D	2015-01-01	2015-12-31	365	2015-12-23 18:15:00	619.0	6702.0	0.09236048940614743	4113.0
ano_2015_sent_D_cat_A	2015-01-01	2015-12-31	365	2015-02-25 14:45:00	90.0	567.0	0.15873015873015872	315.0
ano_2015_sent_D_cat_B	2015-01-01	2015-12-31	365	2015-02-25 14:30:00	68.0	412.0	0.1650485436893204	387.0
ano_2015_sent_D_cat_C	2015-01-01	2015-12-31	365	2015-02-25 14:15:00	58.0	414.0	0.14009661835748793	286.0
ano_2015_sent_D_cat_D	2015-01-01	2015-12-31	365	2015-02-25 14:45:00	52.0	188.0	0.2765957446808511	173.0
ano_2015_sent_D_cat_E	2015-01-01	2015-12-31	365	2015-01-06 07:15:00	31.0	228.0	0.13596491228070176	156.0
ano_2015_sent_D_cat_F	2015-01-01	2015-12-31	365	2015-11-26 16:30:00	12.0	55.0	0.21818181818181817	27.0
ano_2015_sent_D_cat_G	2015-01-01	2015-12-31	365	2015-01-06 08:00:00	4.0	4.0	1.0	1.0
ano_2015_sent_D_cat_H	2015-01-01	2015-12-31	365	2015-07-15 09:30:00	8.0	27.0	0.2962962962962963	10.0
ano_2015_sent_D_cat_I	2015-01-01	2015-12-31	365	2015-12-27 10:00:00	503.0	6004.0	0.08377748167888074	2327.0
ano_2015_sent_D_cat_J	2015-01-01	2015-12-31	365	2015-03-08 13:30:00	55.0	385.0	0.14285714285714285	144.0
ano_2015_sent_D_cat_L	2015-01-01	2015-12-31	365	2015-11-13 10:00:00	27.0	192.0	0.140625	122.0
ano_2015_sent_C	2015-01-01	2015-12-31	365	2015-12-23 09:15:00	797.0	8960.0	0.08895089285714286	3925.0
ano_2015_sent_C_cat_A	2015-01-01	2015-12-31	365	2015-02-25 16:15:00	79.0	615.0	0.12845528455284552	264.0
ano_2015_sent_C_cat_B	2015-01-01	2015-12-31	365	2015-06-01 16:30:00	53.0	480.0	0.11041666666666666	352.0

As categorias usadas pelo SGP já estão sendo implementados





EQ 192 - UF: MG BR 381 KM 266


ano_2015_sent_Ambos_cat_A	2015-01-01	2015-12-31	365	2015-02-25 16:15:00	123.0	1182.0	0.10406091370558376	579.0
ano_2015_sent_Ambos_cat_B	2015-01-01	2015-12-31	365	2015-05-27 16:15:00	91.0	1173.0	0.07757885763000852	740.0
ano_2015_sent_Ambos_cat_C	2015-01-01	2015-12-31	365	2015-02-25 16:15:00	104.0	794.0	0.1309823677581864	494.0
ano_2015_sent_Ambos_cat_D	2015-01-01	2015-12-31	365	2015-02-25 14:45:00	53.0	347.0	0.15273775216138327	328.0
ano_2015_sent_Ambos_cat_E	2015-01-01	2015-12-31	365	2015-03-26 08:15:00	54.0	456.0	0.11842105263157894	345.0
ano_2015_sent_Ambos_cat_F	2015-01-01	2015-12-31	365	2015-07-14 16:45:00	19.0	128.0	0.1484375	75.0
ano_2015_sent_Ambos_cat_G	2015-01-01	2015-12-31	365	2015-05-25 16:15:00	5.0	9.0	0.5555555555555556	4.0
ano_2015_sent_Ambos_cat_H	2015-01-01	2015-12-31	365	2015-05-06 08:45:00	16.0	43.0	0.37209302325581395	29.0
ano_2015_sent_Ambos_cat_I	2015-01-01	2015-12-31	365	2015-12-27 08:30:00	946.0	11802.0	0.08015590577868158	4464.0
ano_2015_sent_Ambos_cat_J	2015-01-01	2015-12-31	365	2015-10-16 17:30:00	72.0	427.0	0.1686182669789227	304.0
ano_2015_sent_Ambos_cat_L	2015-01-01	2015-12-31	365	2015-11-06 17:00:00	49.0	391.0	0.12531969309462915	241.0

Sentidos: C, D, Ambos







UF:MG BR:381 KM:266 - eq.192, sentido D (1 faixa(s)). Período: 2015-01-01 à 2015-12-31 (365 dias válidos)




UF:MG BR:381 KM:266 - eq.192, sentido C (1 faixa(s)). Período: 2015-01-01 à 2015-12-31 (365 dias válidos)



UF:MG BR:50 KM:105 - eq.174, sentido D (2 faixa(s)). Período: 2015-01-01 à 2015-12-31 (365 dias válidos)



UF:MG BR:50 KM:105 - eq.174, sentido C (2 faixa(s)). Período: 2015-01-01 à 2015-12-31 (365 dias válidos)



MUITO OBRIGADO



UNIVERSIDADE FEDERAL
DO RIO DE JANEIRO



COPPE
UFRJ
Instituto Alberto Luis Coimbra de
Pós-Graduação e Pesquisa em Engenharia


COPPETEC
FUNDAÇÃO

Ministério dos
Transportes

GOVERNO FEDERAL
BRASIL
PAÍS RICO E PAÍS SEM POBREZA