

Avaliação de modelos de previsão para quantidade de automóveis no Estado de Santa Catarina

Leandro Callegari Coelho (UFSC) leandroah@hotmail.com
Robert Wayne Samohyl (UFSC) samohyl@yahoo.com

Resumo: Este artigo aborda a comparação em diversos modelos de previsão (Decomposição Clássica, Suavização Exponencial, ARIMA, Regressão dinâmica) aplicados à série de dados histórica da quantidade de automóveis do Estado de Santa Catarina. Na comparação final, a regressão dinâmica apresenta melhor aderência à série, mas é preterida por necessitar de previsão extra para a variável independente eleita. A opção final é pelo modelo ARIMA sazonal, em função dos valores de AIC e U de Theil utilizados na comparação. Com as previsões feitas, estes dados podem servir para análises do sistema viário, planejamento de transporte público e análises de tendências sociais na região estudada, utilizando os sistemas de previsão com a teoria de logística urbana.

Palavras chave: Modelos de previsão; Previsão; Resíduos; Logística Urbana.

1. Introdução

Cada vez mais os grandes centros urbanos enfrentam situações de trânsito congestionado, contribuindo para o stress e perda em qualidade de vida de quem vive nessas cidades. Muito se tem discutido em logística sobre a necessidade de se fazer compartilhamento de caminhões para as entregas em áreas urbanas, diminuindo a necessidade de vários veículos para fazer abastecimento de mercados, lojas, etc (DUTRA, 2004).

Um novo enfoque a ser considerado é a falta de um transporte público eficiente, que acarreta em um enorme número de automóveis particulares em circulação. Assim, acredita-se que um dos principais motivadores da super utilização da capacidade viária das cidades é decorrente do excesso de automóveis. O rodízio de veículos ocorrido em São Paulo é uma confirmação de que esta preocupação não é trivial. Como formador deste cenário temos duas causas principais: uma é comportamental (no sentido de que o habitante prefere o deslocamento particular) e outra é governamental (pois não há investimento suficiente para suprir as necessidades de transporte coletivo).

Sobre o prisma do cidadão, frente às condições precárias de transporte público como superlotação, longas esperas, itinerário nem sempre favorável e higiene ou até mesmo outras variáveis como comodidade e status, é justificável que este opte pelo transporte particular.

Posto isso, o intuito deste artigo é traçar cenários de previsão do número de automóveis no estado de Santa Catarina para servir de base para avaliações que norteiem atividades futuras em relação ao urbanismo, investimentos em transportes públicos e necessidades viárias.

2. Metodologia

Os dados da quantidade de veículos no estado de Santa Catarina foram obtidos no site do Departamento de Trânsito do Estado, com frequência mensal, iniciando em janeiro de 2002 até o mês de abril de 2007, configurando 64 observações para automóveis, motocicletas,

ônibus, microônibus, caminhonetes (transporte de carga) e camionetas (transporte misto de carga e pessoas). (Fonte: <http://www.detran.sc.gov.br>)

Estes dados servirão para realizar o estudo de caso para aplicação de diversos modelos de previsão, que serão descritos a seguir. Por tratar-se de dados quantitativos, serão então aplicadas técnicas formais de estatística a fim de se obter conclusões definitivas sobre o tema.

O Anexo A mostra a tabela de dados para automóveis e motocicletas, conforme descrito acima. Na Figura 01 abaixo é mostrada a evolução mensal da variável de interesse.

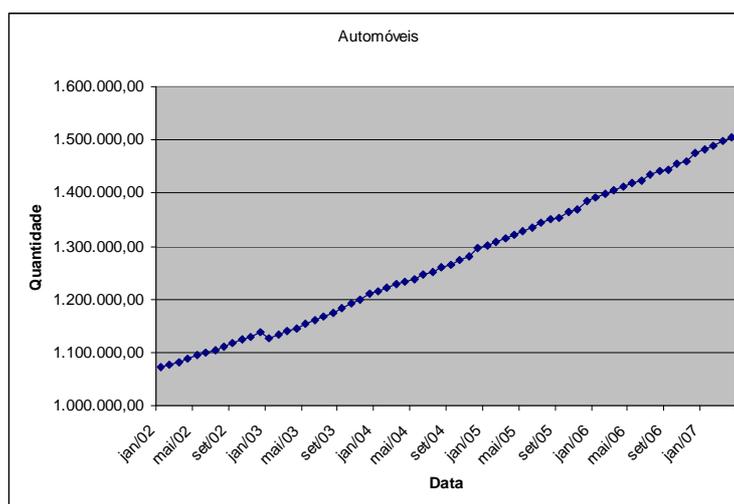


Figura 01 – Número mensal de automóveis registrados no DETRAN/SC

Ferramentas de análise estatística e alguns modelos de previsão serão utilizados para modelar o comportamento da variável ao longo do tempo, e fazer previsões para os próximos meses. Os métodos de previsão a serem utilizados neste artigo são divididos entre univariados (Previsão Ingênua, Decomposição clássica, Suavização exponencial - Holt winters, ARIMA) e multivariado (Regressão dinâmica).

Para eleição do melhor método dentre os propostos neste artigo, serão utilizados em conjunto dois critérios:

- AIC (Akaike Information Criterion), Equação 01, que permite fazer o “trade-off” entre uma redução na soma do quadrado dos resíduos estimados e um modelo mais parcimonioso.

$$AIC = T \ln (\text{soma do quadrado dos resíduos}) + 2n \quad (\text{Equação 01})$$

Sendo n o número de parâmetros estimados e T o número de observações utilizadas.

- U de Theil, Equação 02, que avalia o desempenho da previsão em relação à previsão ingênua ou trivial. Previsão ingênua ou trivial significa que a estimativa do valor futuro é igual ao valor atual. O coeficiente U de Theil analisa a qualidade de uma previsão através dos seguintes valores:

- $U > 1$, significa que o erro do modelo é maior do que da previsão ingênua;
- $U < 1$, significa que o erro do modelo é menor que da previsão ingênua.

O coeficiente U de Theil menor do que 1 já indica uma previsão melhor que a previsão ingênua; quanto mais próximo o mesmo for de zero, melhor será o resultado da previsão.



$$U \text{ de THEIL} = \frac{\sqrt{\sum_{j=1}^N (\text{observado}_j - \text{previsto}_j)^2}}{\sqrt{\sum_{j=1}^N (\text{observado}_j - \text{observado}_{j-1})^2}} \quad (\text{Equação 02})$$

3. Aplicação

3.1. Previsão ingênua

Apenas considera que a posição da variável no futuro será igual à última observação realizada. Na ausência de um modelo mais sofisticado, inicialmente a melhor alternativa é a previsão ingênua, por sua facilidade de aplicação. Segundo Samohyl (2007), este método se presta principalmente como um comparador para outros modelos mais complexos.

Para este conjunto de dados, a previsão ingênua apresenta um erro percentual baixo, com o indicador de Erro Percentual Absoluto Médio (EPAM) de 0,57 %.

3.2. Suavização exponencial

Este método apóia-se apenas nos dados da própria série para fazer previsões, não necessitando de nenhuma variável independente. Isto traz a vantagem da rapidez, uma vez que não é necessário buscar ou medir outras variáveis. Segundo Samohyl e Miranda (2007), este método decompõe a série em suas componentes de tendência e sazonalidade e suaviza os dados históricos exponencialmente, de forma que valores antigos tendem a ter peso zero, valorizando as observações mais recentes.

Segundo HANKE, REITSCH e WICHERN 2001, o Método de Holt-Winters, é indicado quando está se trabalhando com dados sazonais, sem necessariamente estacioná-los. Destaca-se que este método deve ser utilizado para gerar previsões de curto prazo.

Utilizando software R, com pacote Forecast, o melhor modelo de suavização exponencial dos dados analisados, com critério de escolha do menor AIC, foi o método de Holt-Winters aditivo, com as três componentes de suavização exponencial: alfa = 0,9319 (nível); beta = 0,1031 (tendência); gama = 0,0114 (sazonalidade). É importante avaliar os resíduos da previsão, que se mostraram aleatórios e de acordo com a distribuição normal.

A título de comparação com o EPAM obtido com a previsão ingênua (que foi de 0,57%), este modelo apresentou EPAM = 0,12%. Os indicadores que servirão de comparação com os demais métodos tiveram os seguintes valores: AIC = 1294,12 e U de Theil = 0,3514.

3.3. Decomposição Clássica

A modelagem de uma série temporal através da decomposição clássica, segundo Makridakis et al (1998) é um procedimento descritivo, baseado na análise da série em questão em quatro componentes fundamentais: (1) tendência, que verifica o sentido de deslocamento da série ao longo do tempo, podendo ser crescente ou decrescente; (2) ciclo, movimento ondulatório que ao longo de vários anos tende a ser periódico, mas sem duração uniforme; (3) sazonalidade, que tem a duração de curto prazo, inferior a um ano, mas apresenta-se de maneira semelhante ao ciclo; (4) aleatoriedade, de difícil modelagem.

De acordo com Souza, Samohyl e Meurer (2004), a decomposição clássica é uma ferramenta útil, pois permite fazer previsões e auxilia na tomada de decisões sobre outros métodos de previsão que melhor se adequem aos dados disponíveis.

Para realizar a modelagem utilizando a técnica de decomposição clássica, é recomendado que a série temporal seja estacionária. Para tanto, será utilizada inicialmente a primeira diferença dos dados. Esta nova série pode ser visualizada na Figura 02.

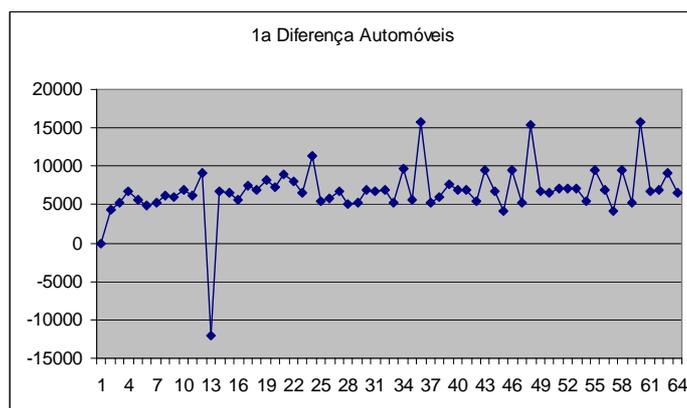


Figura 02 – Primeira diferença da série Automóveis

Agora sim, nota-se que a série é estacionária no tempo, e inclusive a sazonalidade fica muito mais perceptível. Com estes dados, já é possível realizar a modelagem de decomposição clássica em suas componentes, para futura realização de previsões.

O modelo de decomposição escolhido é o aditivo, e a função que apresenta a melhor reta de ajuste é mostrada na equação 03, e os índices sazonais mensais na Tabela 01.

$$DY_t = 5392 + 46,9 t \quad (\text{Equação 03})$$

Tabela 01 – Índices sazonais da decomposição para primeira diferença

Mês	Índice	Mês	Índice	Mês	Índice
Janeiro	-1235,85	Mai	-1071,23	Setembro	1783,50
Fevereiro	-46,54	Junho	1598,29	Outubro	-1339,65
Março	-636,20	Julho	-343,10	Novembro	5909,25
Abril	-650,39	Agosto	-1970,73	Dezembro	-1997,35

Para este modelo, os valores de U de Theil e AIC a serem comparados com os demais ao final são respectivamente 0,4611 e 1241,12.

Os resíduos são aleatoriamente distribuídos, em torno de zero, no entanto não são normais. Para tentar corrigir este problema de ajustamento, será feita a segunda diferença dos dados (D_2Y_t) e um novo modelo de decomposição será ajustado.

O modelo de decomposição escolhido é o aditivo, e a função que apresenta a melhor reta de ajuste é mostrada na equação 04 e os índices sazonais mensais na Tabela 02. Para este modelo, os resíduos apresentam-se aleatórios, e ainda centrados em zero.

$$D_2Y_t = 58 - 0,9360 t \quad (\text{Equação 04})$$

Tabela 02 – Índices sazonais da segunda decomposição

Mês	Índice	Mês	Índice
Janeiro	1084,36	Julho	-1393,30
Fevereiro	-645,55	Agosto	4430,53
Março	295,37	Setembro	-2463,63

Abril	-823,82
Mai	2426,93
Junho	-1889,17

Outubro	7671,85
Novembro	-9383,70
Dezembro	690,14

Para este modelo, os valores dos parâmetros a serem avaliados são: AIC = 1259 e U de Theil = 0,3487.

Note-se que para ambos os casos, será preciso fazer a transformação inversa a fim de obter o valor da quantidade de automóveis, e não da segunda diferença.

As decomposições clássicas ora apresentadas estão baseadas na literatura amplamente discutida sobre o assunto, e apresentam uma reta que ajusta os dados originais para obtenção do menor erro. Esta reta é composta pelo parâmetro t (tempo). No entanto, dada a variação nos dados, é possível tentar estimar uma equação com parâmetros não lineares, utilizando t^2 e t^3 . Ainda, para substituir os índices sazonais, criam-se variáveis dummy para cada um dos meses, não permitindo existência do intercepto (constante), para evitar singularidade na matriz trabalhada. Os parâmetros calculados e respectivos p-valores são listados na Tabela 03.

Todos os coeficientes, calculados através de regressão simples, são significativamente diferentes de zero, e apresentam uma boa estimativa final na composição da série modelada. Esta abordagem tem sido utilizada por Samohyl, e tem como vantagem a fácil aplicação em ambientes empresariais, normalmente gerando resultados muitas vezes adequados: neste modelo, o maior resíduo individual é de 8.895 unidades – representando menos de 1% de erro máximo individual, pois o alvo nesta observação é de 1.126.691.

Para este modelo, chamado de Decomposição Clássica Alternativa, os valores de AIC e U de Theil são respectivamente 1307,96 e 0,4191.

Tabela 03 – Coeficientes e significância da decomposição alternativa.

Coeficientes					
	Estimativa	Pr(> t)		Estimativa	Pr(> t)
t	4,097E+03	< 2e-16	mai	1,070E+06	< 2e-16
t ²	7,341E+01	1.75e-10	jun	1,069E+06	< 2e-16
t ³	-5,017E-01	1.79e-06	jul	1,070E+06	< 2e-16
jan	1,071E+06	< 2e-16	ago	1,070E+06	< 2e-16
fev	1,070E+06	< 2e-16	set	1,069E+06	< 2e-16
mar	1,071E+06	< 2e-16	out	1,071E+06	< 2e-16
abr	1,071E+06	< 2e-16	nov	1,070E+06	< 2e-16
			dez	1,076E+06	< 2e-16

3.4. ARIMA

Os modelos ARIMA são resultado da combinação de três componentes, como define o acrônimo: Auto-Regressive Integrated Moving Average. O componente auto-regressivo (AR), o filtro de integração (I) e o componente de médias móveis (MA). Uma série pode ser modelada pelos três filtros ou apenas um subconjunto deles, resultando em várias combinações de modelos possíveis.

O objetivo é buscar os valores p , d , q que formem um modelo $ARIMA(p,d,q)$, que melhor se ajuste aos dados da série analisada.

Inicialmente, observa-se que nas funções de autocorrelação, mostrada na Figura 03, há uma lenta queda dos pregos da função, sendo necessário que seja feita uma transformação para deixá-la estacionária, neste caso a primeira diferença.

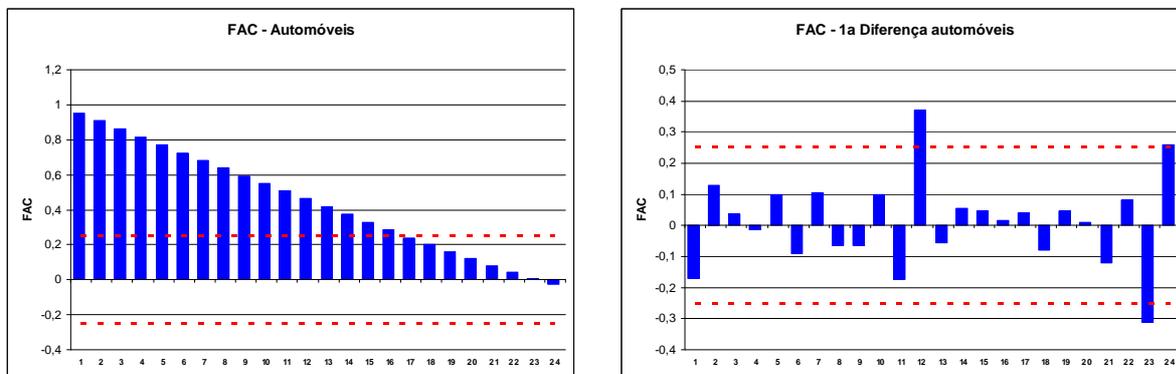


Figura 03 – Funções de Autocorrelação de Automóveis e sua diferença

A função de autocorrelação parcial é mostrada na Figura 04, apresentando um prego significativo na 12ª defasagem, indicando possibilidade já conhecida de haver sazonalidade de período 12.

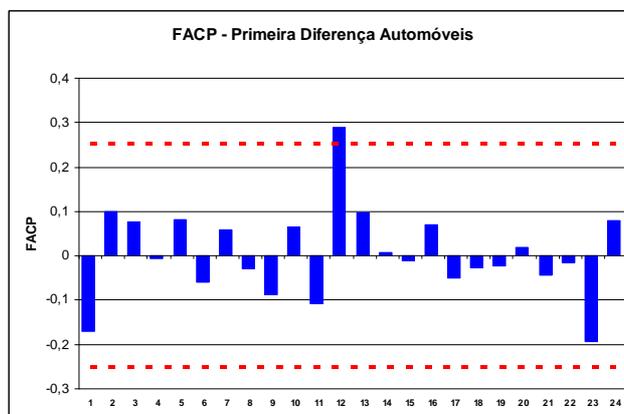


Figura 04 – Função de autocorrelação parcial para primeira diferença de automóveis

Inicialmente, propõe-se um modelo $ARIMA(0,1,1)(1,0,0)_{12}$, pois este cumpre o papel da 1ª diferença que deixa a variável estacionária, apresenta uma componente de média móvel (para o crescimento da série), e tem uma componente auto regressiva sazonal de período 12. Este primeiro modelo proposto cumpre seu papel adequadamente, com U de Theil igual a 0,3305 e $AIC = 1208$.

Novamente com auxílio do software R, utilizando a função *best.arima*, escolhida pelo critério do menor AIC, a solução ótima é: $ARIMA(0, 2, 1)(1, 0, 0)_{12}$, levemente diferente do modelo proposto. Os valores dos critérios de seleção escolhidos neste artigo são: $AIC = 1171$ e U de Theil = 0,3305.

Os resíduos deste modelo não apresentam autocorrelação nem autocorrelação parcial significativos, como mostra a Figura 05, e a distribuição dos resíduos obedece à característica de normalidade.

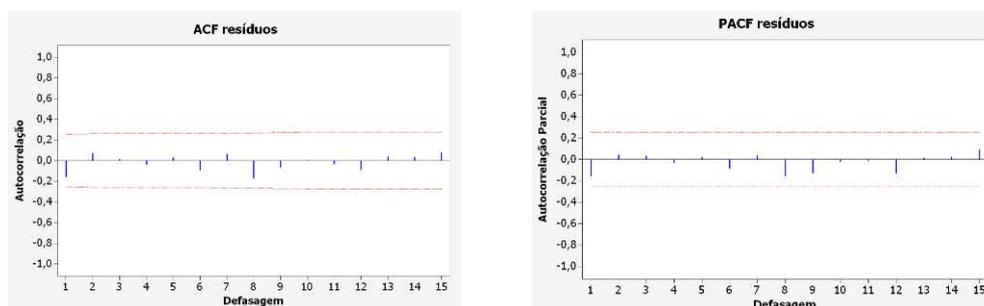


Figura 05 – Funções de autocorrelação e autocorrelação parcial dos resíduos

3.5. Regressão Dinâmica

Segundo HANKE, REITSCH e WICHERN 2001, os métodos de regressão adaptam-se melhor a dados com ciclo e sazonalidade mais marcantes e com os quais se deseja realizar previsões, notadamente de médio e longo prazos.

Para a modelagem da regressão dinâmica, as variáveis imediatas a serem escolhidas para essa construção são os números de outros veículos registrados no DETRAN/SC. Para este trabalho, será considerada a quantidade de motocicletas.

As variáveis que serão utilizadas na análise de regressão devem atender três requisitos básicos: estacionariedade, linearidade e normalidade (SAMOHYL, 2007). Para atender a estes requisitos, foi feita a segunda diferença de cada uma das variáveis, a exemplo do ocorrido no modelo ARIMA, deixando-as estacionárias, atendendo ao primeiro requisito.

Para confirmar a eleição da variável independente para a regressão a ser feita, é necessário confirmar a correlação entre as variáveis. O índice de correlação entre automóveis e motocicletas é de 0,9103. Apesar do alto grau de correlação entre as variáveis, para Samohyl (2007), haver correlação não necessariamente implica em haver relação de causa e efeito entre as variáveis, apenas relacionamento. Após escolha desta variável, faz-se necessário verificar a normalidade dos dados e a linearidade entre as duas variáveis escolhidas, mostradas nas Figuras 06 e 07, para posterior análise de regressão.

Assim, com auxílio do software PC GETS, foi realizada regressão dinâmica, com 12 defasagens da variável automóveis, constante, motocicletas e suas 12 defasagens. Após algumas iterações e retiradas de variáveis não significantes, o modelo resultante está mostrado na Tabela 04, com AIC de 1161 e U de Theil igual a 0,1627.

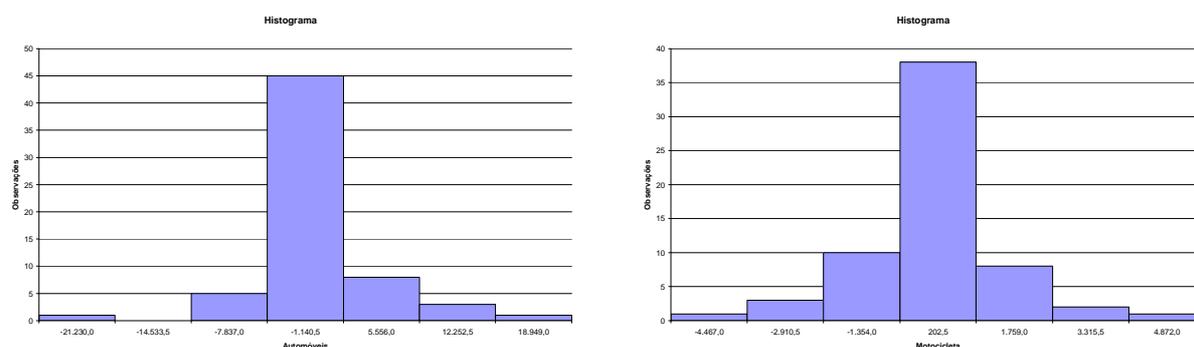


Figura 06 – Histograma das duas variáveis, indicando normalidade nos dados

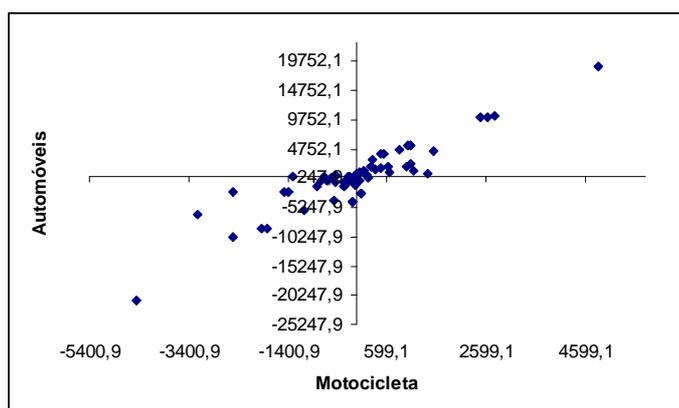


Figura 07 – Dispersão das variáveis analisadas - linearidade

Tabela 04 – Resumo do modelo da regressão

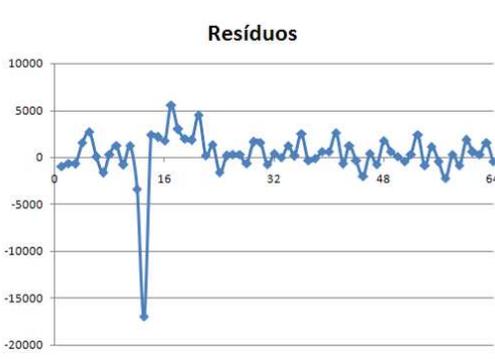
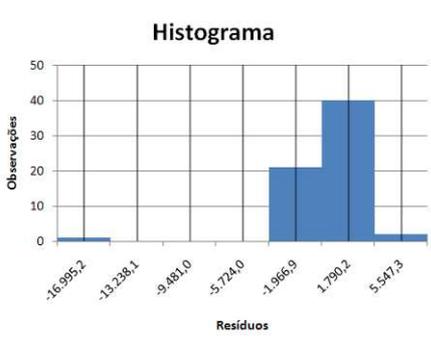
Variável	Coefficiente	Probabilidade t-student
Automóvel_1	-0,3661	0,003
Automóvel_12	0,6132	0,000
Motocicleta	2,9347	0,000
Motocicleta_1	1,2425	0,004
Motocicleta_12	-2,0190	0,000

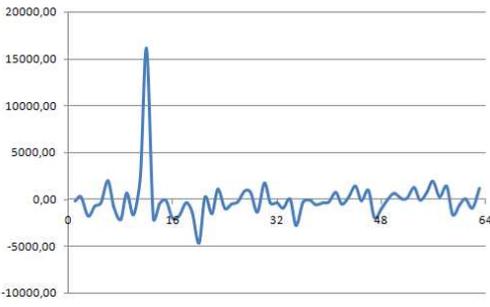
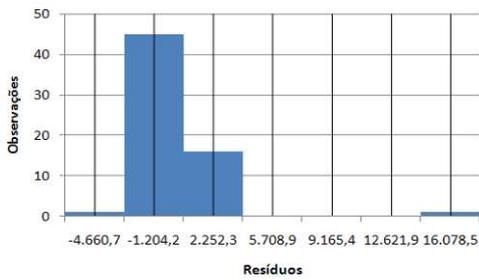
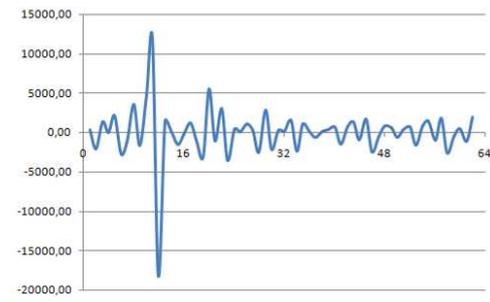
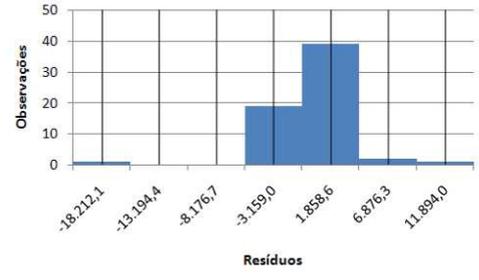
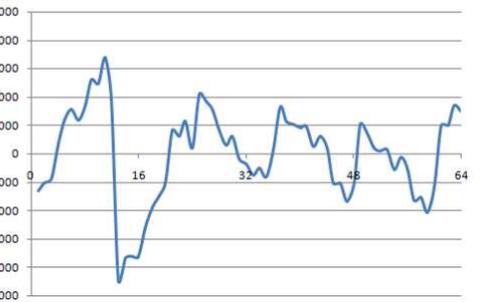
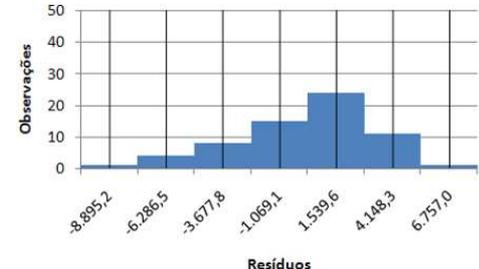
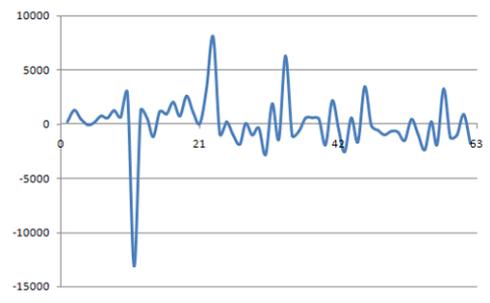
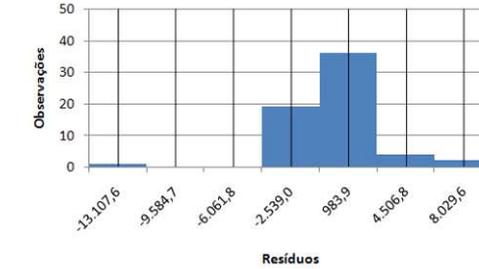
Os resíduos desta modelagem apresentam distribuição normal.

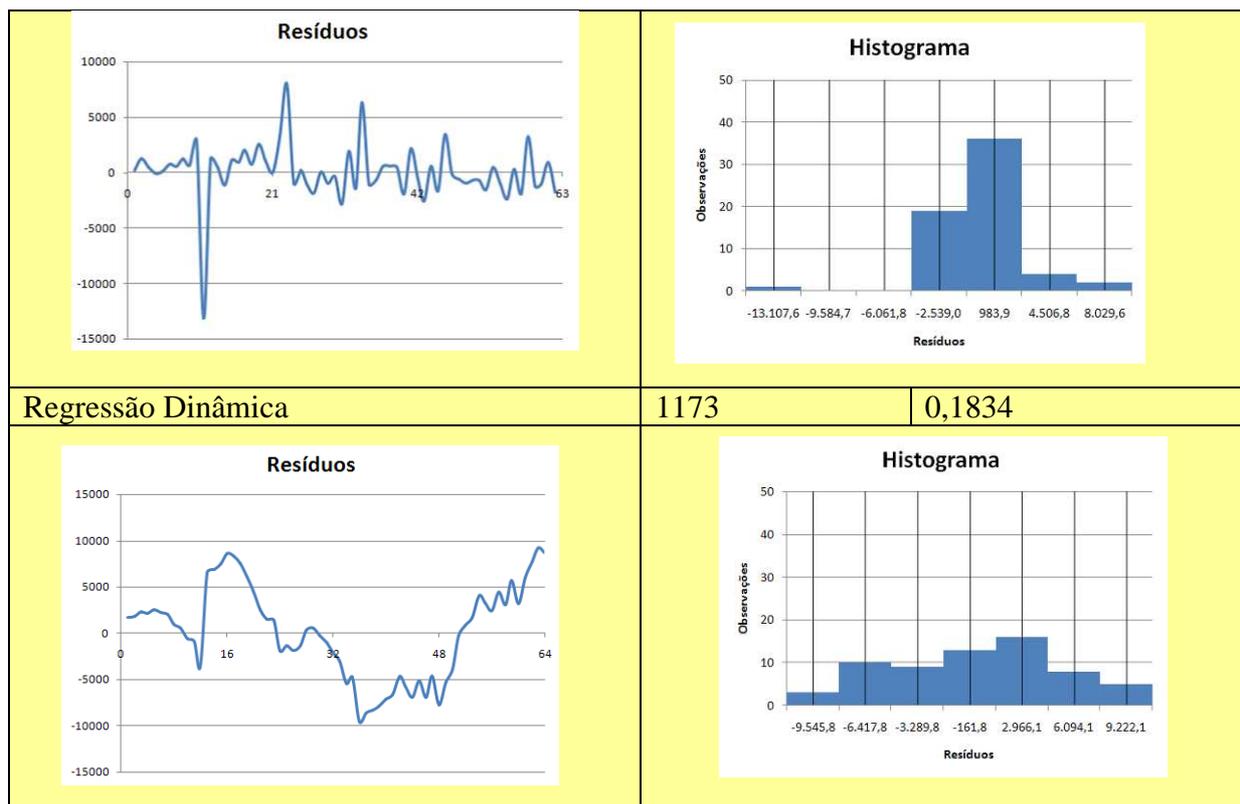
4. Análise dos resultados

A comparação de todos os modelos propostos, seus valores para U de Theil e AIC, juntamente com características dos resíduos (variação temporal e histograma), é mostrada na Tabela 05.

Tabela 05 – Resumo dos resultados

Modelo	AIC	U de Theil
Suavização Exponencial – Holt Winters	1294,12	0,3514
		
Decomposição Clássica – 1ª diferença	1241,12	0,4611

<p style="text-align: center;">Resíduos</p> 	<p style="text-align: center;">Histograma</p> 	
<p>Decomposição Clássica – 2ª diferença</p>	<p>1259,00</p>	<p>0,3487</p>
<p style="text-align: center;">Resíduos</p> 	<p style="text-align: center;">Histograma</p> 	
<p>Decomposição Clássica Alternativa</p>	<p>1307,96</p>	<p>0,4191</p>
<p style="text-align: center;">Resíduos</p> 	<p style="text-align: center;">Histograma</p> 	
<p>ARIMA (0,1,1)(1,0,0)₁₂</p>	<p>1208,00</p>	<p>0,3305</p>
<p style="text-align: center;">Resíduos</p> 	<p style="text-align: center;">Histograma</p> 	
<p>ARIMA (0,2,1)(1,0,0)₁₂</p>	<p>1171,00</p>	<p>0,3305</p>



Nesta situação, os melhores métodos dentre os estudados neste artigo são o segundo modelo ARIMA proposto e a regressão dinâmica. Para esta, no entanto, encontra-se um problema, uma vez que ela requer a variável motocicleta no mesmo período da previsão desejada para automóveis, além de várias defasagens das duas variáveis.

Para fazer a previsão para 12 períodos subseqüentes, faz-se necessário uma *outra* previsão para as motocicletas. Isto, além de incorporar novos erros de previsão, requer tempo, e ainda a medição de uma variável independente para finalmente obter as previsões desejadas.

Desta forma, talvez passe a ser interessante utilizar um modelo univariado para estas previsões, e a escolha pelos mesmos critérios mostrados na Tabela 04 é do ARIMA, em função de 2 características: (1) os resíduos do modelo não apresentaram autocorrelações nem distorção na distribuição dos dados; (2) as previsões podem ser feitas sem apoio de outras variáveis, que poderiam necessitar de previsões, baseando-se apenas nos próprios dados.

Assim, a curva de dados original e a previsão para os próximos 12 períodos é mostrada na Figura 08. Note-se também a presença de limites de confiança para previsão, ao nível de 95%. Neste nível normalmente têm-se limites muito abertos, dando margem para muitas interpretações da previsão, mas neste caso os limites são bem próximos e com característica bastante semelhante à previsão em si. Também na Tabela 06 são mostrados os valores alvo da previsão para os próximos 12 meses.

Tabela 06 – Valores previstos

Período	Previsão
Mai / 2007	1.513.274
Junho / 2007	1.520.941
Julho / 2007	1.530.644

Período	Previsão
Novembro / 2007	1.563.658
Dezembro / 2007	1.576.578
Janeiro / 2008	1.585.087

Agosto / 2007	1.539.056	Fevereiro / 2008	1.593.720
Setembro / 2007	1.546.121	Março / 2008	1.603.510
Outubro / 2007	1.555.923	Abril / 2008	1.612.019

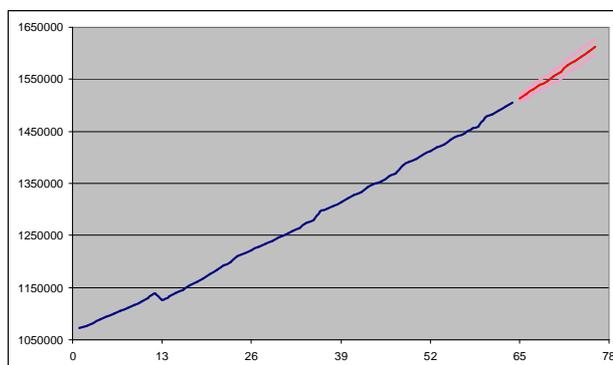


Figura 08 – Curva original, previsão e limites de confiabilidade

5. Conclusão

Após a formulação de vários modelos e da comparação entre eles, percebe-se que a maioria produziria resultados aceitáveis para a variável de interesse. No entanto, poder prever com maior precisão o número de automóveis em circulação é de extrema importância, seja para traçar perfis sociais da população, seja para moldar políticas públicas de incentivo e melhoria do transporte coletivo, ou ainda para dimensionamento da capacidade viária das cidades. Para quaisquer das atividades finais, é importante se ter em mente o contínuo crescimento da quantidade de automóveis em circulação no estado.

A utilização de diversos métodos para comparação se mostra eficiente, na medida em que faz a eleição daquele que produzirá melhores resultados, mesmo sem ter despendido o maior esforço, como foi o caso deste artigo.

Inicialmente poderia-se supor que o método de regressão dinâmica seria o mais eficiente por utilizar o histórico da variável e se apoiar em variáveis extras, independentes. No entanto, a escolha final foi feita a favor de um método univariado, que utilizou diferenciações, sazonalidade e médias móveis, o ARIMA. Esta escolha traduz-se em boas previsões de curto prazo, até que os parâmetros do modelo sejam re-estimados, sem necessidade de tempo e/ou custos para medição/previsão de outras variáveis, como seria o caso da regressão.

Observa-se ainda que apesar de terem sido utilizadas técnicas amplamente difundidas na literatura, as conclusões não podem ser extrapoladas para outras situações que não a descrita neste trabalho, visto que a generalização poderia não ser válida. Finalmente, destaca-se a importância da análise dos resíduos fora da amostra, que não puderam ser analisados no neste artigo pela baixa quantidade de observações disponíveis.

Referências

DETRAN Santa Catarina – <http://www.detran.sc.gov.br>. Acesso em junho de 2007.

DUTRA, Nadja Glheuca da Silva; NOVAES, Antonio Galvão Naclério; **O enfoque de city logistics na distribuição urbana de encomendas**. Tese (Doutorado em Engenharia de Produção). Departamento de Engenharia de Produção e Sistemas, Universidade Federal de Santa Catarina. Florianópolis, 2004.

HANKE, John L. Reitsch, ARTHUR G. e WICHERN, Dean W. *Business Forecasting*. Prentice Hall, New Jersey. 2001.

MAKRIDAKIS, S., WHEELWRIGHT, S.C. & HYNDMAN, R.J. (1998) - *Forecasting. Methods and Applications*. Third Edition. John Wiley & Sons. New York.

MIRANDA, R. G. de, SAMOHYL, R. W. Métodos de suavização exponencial. 2007. Disponível em <http://www.webensino.ufsc.br>

SAMOHYL, R. W. Correlação. 2007. Disponível em <http://www.webensino.ufsc.br>

SAMOHYL, R. W. Métodos de previsão univariados. 2007. Disponível em <http://www.webensino.ufsc.br>

SOUZA, G. P., SAMOHYL, R. W., MEURER, R. (2004). Previsão do consumo de energia elétrica do setor industrial em Santa Catarina – um estudo comparativo entre diferentes métodos de previsão através de suas discrepâncias. Disponível em <http://www.qualimetria.ufsc.br>

ANEXO A – Tabela de veículos no Estado de Santa Catarina, dados mensais

Mês	Automóveis	Motocicleta
jan/02	1.072.573,00	248.445,00
fev/02	1.076.918,00	250.832,00
mar/02	1.082.103,00	253.860,00
abr/02	1.088.754,00	257.363,00
mai/02	1.094.416,00	260.597,00
jun/02	1.099.352,00	263.094,00
jul/02	1.104.620,00	265.790,00
ago/02	1.110.766,00	268.521,00
set/02	1.116.691,00	271.474,00
out/02	1.123.577,00	274.563,00
nov/02	1.129.703,00	277.694,00
dez/02	1.138.812,00	281.124,00
jan/03	1.126.691,00	280.087,00
fev/03	1.133.519,00	283.922,00
mar/03	1.139.995,00	287.715,00
abr/03	1.145.592,00	291.306,00
mai/03	1.153.037,00	295.158,00
jun/03	1.159.921,00	298.383,00
jul/03	1.168.092,00	301.979,00
ago/03	1.175.385,00	305.124,00
set/03	1.184.405,00	308.891,00
out/03	1.192.363,00	312.581,00
nov/03	1.198.941,00	316.042,00
dez/03	1.210.220,00	320.349,00
jan/04	1.215.686,00	323.588,00
fev/04	1.221.476,00	326.391,00
mar/04	1.228.283,00	330.328,00
abr/04	1.233.439,00	334.004,00
mai/04	1.238.745,00	336.998,00
jun/04	1.245.746,00	340.280,00
jul/04	1.252.393,00	343.436,00
ago/04	1.259.293,00	346.582,00

Mês	Automóveis	Motocicleta
set/04	1.264.611,00	348.914,00
out/04	1.274.238,00	352.789,00
nov/04	1.279.884,00	356.189,00
dez/04	1.295.623,00	362.076,00
jan/05	1.300.977,00	365.465,00
fev/05	1.306.950,00	368.832,00
mar/05	1.314.669,00	373.188,00
abr/05	1.321.620,00	377.341,00
mai/05	1.328.549,00	381.331,00
jun/05	1.334.004,00	385.286,00
jul/05	1.343.423,00	389.729,00
ago/05	1.350.221,00	392.777,00
set/05	1.354.288,00	395.894,00
out/05	1.363.705,00	400.018,00
nov/05	1.368.966,00	404.054,00
dez/05	1.384.419,00	410.701,00
jan/06	1.391.081,00	415.541,00
fev/06	1.397.624,00	419.841,00
mar/06	1.404.686,00	425.555,00
abr/06	1.411.737,61	429.964,32
mai/06	1.418.766,90	434.200,58
jun/06	1.424.300,86	438.399,68
jul/06	1.433.856,19	443.116,90
ago/06	1.440.752,59	446.353,02
set/06	1.444.878,45	449.662,40
out/06	1.454.431,76	454.040,93
nov/06	1.459.768,90	458.326,03
dez/06	1.475.445,57	465.383,28
jan/07	1.482.204,00	470.522,00
fev/07	1.489.143,00	475.176,00
mar/07	1.498.338,00	480.910,00
abr/07	1.504.896,00	484.137,00