

PRINCIPAIS TÉCNICAS E VARIÁVEIS EMPREGADAS NA MODELAGEM DO CONSUMO DE COMBUSTÍVEIS PELO SETOR DE TRANSPORTES: UMA REVISÃO

Nair Cristina Margarido Brondino

UNESP – Faculdade de Ciências - Departamento de Matemática
Av. Luiz Edmundo Carrijo Coube, 14-01 – CEP 17033-360, Bauru, SP
brondino@fc.unesp.br

Odney Carlos Brondino

UTFPR - Universidade Tecnológica Federal do Paraná, Campus Londrina
Departamento Acadêmico de Engenharia de Materiais
Avenida dos Pioneiros, 3131, CEP 86036-370, Londrina, PR
odneybrondino@utfpr.edu.br

RESUMO

O setor de transportes consome mais da metade do petróleo utilizado no mundo e é responsável por, aproximadamente, 25% das emissões de dióxido de carbono. Tomando-se por base o ano de 2005, estudos preveem que a energia consumida pelo setor aumente em 50% até o ano de 2030 e mais de 200% até 2050. Tendo em vista que boa parte da energia utilizada pelo transporte é proveniente de fontes não renováveis, pesquisadores têm se dedicado a modelar o consumo de energia por esse setor, com o objetivo de realizar previsões de curto e médio prazos. Existe uma pluralidade de fatores e metodologias empregadas em estudos que trataram o tema e, dentro deste contexto, este trabalho consiste em uma pesquisa qualitativa, de natureza exploratória, na qual será divulgada uma revisão bibliográfica com vistas a apresentar as variáveis, os diferentes métodos utilizados e as conclusões obtidas por autores que discutiram o tema.

PALAVRAS CHAVE. Consumo de combustíveis. Transportes. Revisão da Literatura.

Área principal: L&T – Logística e Transportes

ABSTRACT

The transportation sector consumes a half of the petroleum used in the world and contributes with almost 25% of carbon dioxide emissions. Using the year 2005 as the base year, studies preview that the energy consumed by the sector will increase 50% until 2030 and more that 200% until the year 2050. A great part of the energy used by transportation comes from nonrenewable fonts and many researches have been studying best manners to modelling the energy consumption by the sector. There are many factors and methods employed in these types of studies and, in this context, this work has as goal to present a literature review about the variables and methods used in these works and the conclusions obtained by the authors that discussed the subject.

KEYWORDS. Fuel Consumption. Transportation. Literature Review.

Main area: L&T – Logistic and Transportation

1. Introdução

O setor de transportes consome mais da metade do petróleo utilizado no mundo e contribui com aproximadamente 25% das emissões de dióxido de carbono. De acordo com Anable et. al. (2012), tomando o ano de 2005 como base, espera-se que a energia consumida com transporte aumente em 50% até o ano de 2030 e mais de 200% até 2050, devido ao rápido crescimento do número de veículos, em especial as pequenas vans e utilitários esportivos, e também ao aumento da demanda por viagens de avião e transporte rodoviário.

O transporte é essencial para o desenvolvimento econômico sustentável e para a promoção de melhores padrões de vida. Entretanto, entre os outros setores consumidores de energia, ele aparece como um dos maiores desafios para atingir objetivos sustentáveis, no que diz respeito à conservação, diversificação e controle de emissões. De acordo com Moraes (2005), a constituição da frota (veículos automotores, locomotivas, embarcações e aeronaves) é fator de fundamental importância para a determinação do consumo de combustíveis e sua evolução repercutirá preponderantemente na qualidade de vida da população, na dinâmica e competitividade do comércio, no consumo de combustíveis e no impacto ambiental, entre outros.

O consumo de energia com transportes apresenta maior intensidade em países emergentes, como o Brasil. O desenvolvimento da agricultura e da indústria implicam em aumento do transporte de passageiros e insumos. A urbanização requer maior mobilidade para as pessoas, para os alimentos e bens manufaturados, que serão distribuídos para destinos novos e mais distantes. Mudanças nos modos de transportes utilizados também podem contribuir para a tendência ascendente no consumo de combustível, assim como o aumento das viagens para lazer. Além disso, a posse do carro nas sociedades emergentes não só representa um aumento na mobilidade como também reflete um fator de *status* social. Em muitas economias, o número de viagens e de automóveis estão aumentando em uma velocidade muito maior que a renda (Birol e Guerer, 1993).

Muitos especialistas consideram que os sistemas de transporte não são sustentáveis devido ao aumento do uso de automóveis, ou seja, a um aumento do transporte individual nas últimas décadas. Por outro lado, embora o transporte seja um ponto chave quando se busca sustentabilidade, ele oferece às pessoas acesso às oportunidades econômicas e sociais que são necessárias para uma vida plena. De acordo com Wohlgemuth (1997), muitos fatores influenciam uma pessoa a adquirir um veículo, tais como a frequência com que o carro é usado e como a escolha de outros modos de transporte podem influenciar no plano de viagem. Segundo o autor, diferenças no GDP (Gross Domestic Product – equivale ao PIB brasileiro) não são suficientes para explicar variações na demanda de energia para o transporte. Somados à renda, outros fatores tais como custo da viagem, disponibilidade e preços de passagens pelo transporte público, preços dos veículos, qualidade da infraestrutura de transportes, padrões sociais, climáticos, físicos e geográficos, além de políticas vigentes, podem ditar regras importantes no consumo. O autor afirma, ainda, que os fatores determinantes de uma viagem podem ser agrupados em econômicos, sócio demográficos e geográficos, os quais interagem entre si. Os determinantes econômicos são, essencialmente, renda e custo da viagem. Os fatores sócio demográficos incluem tamanho e estrutura da família, gênero, *status* no trabalho e idade da população. Ele afirma, ainda, que as condições geográficas também influenciam a demanda por viagens, por meio da densidade populacional e distâncias entre destinos. Embora o nível de transportes de bens por rodovias em um país seja dependente principalmente do tamanho do seu GDP, o aspecto geográfico é um fator determinante na quantidade de bens transportados por ferrovias, por exemplo. Desta forma, os determinantes chave para a demanda de energia pelo transporte não são simplesmente os fatores econômicos, mas também geográficos, demográficos e os estilos de vida. Variáveis não menos importantes são as mudanças no mercado de trabalho, o espalhamento da população em direção aos subúrbios e a imposição de taxas ou outras políticas públicas.

Enquanto existe uma crença de que um padrão urbano descentralizado promova um aumento no consumo de combustíveis, o trabalho de Naess (2012), a partir de uma análise de estudos realizados nos países nórdicos, conclui que, enquanto em escala intrametropolitana um

padrão centralizado de desenvolvimento requer menos energia para o transporte, a descentralização pode ser um padrão mais eficiente energeticamente em escala regional, em uma situação de baixa mobilidade.

Apesar de um consenso amplamente aceito de que o consumo de energia e consequentes emissões são influenciados não apenas pela eficiência técnica, mas também pelo estilo de vida e fatores socioculturais (por exemplo, tamanho e composição das famílias, padrões de despesa, normas sociais, hábitos e envelhecimento da população), Anable et. al. (2012) afirmam que há uma lacuna metodológica entre a importância percebida desses fatores para a demanda de energia e ferramentas de modelagem quantitativa ou análise de cenários. De acordo com estes autores, poucas tentativas têm sido feitas com o objetivo de incluir fatores psicossociais, tais como o bem estar, normas e valores sociais em modelos de previsão de demanda por energia.

Diante do exposto, observa-se que existe uma vasta gama de fatores que podem influenciar o consumo de energia pelo transporte, que podem variar de país para país, o que torna a escolha das variáveis a serem utilizadas um problema a ser avaliado com cuidado.

Em adição, tendo em vista que muitas das fontes energéticas são finitas, a crescente demanda mundial por energia requer o desenvolvimento de métodos e algoritmos de previsão eficientes, com vistas a um planejamento adequado e consequente proposição de políticas que visem a utilizar tais fontes de modo a otimizar sua capacidade de fornecimento. Entretanto, a principal dificuldade em modelar a demanda por energia em transportes é dada pelo fato de que ela é uma demanda derivada, que depende de muitos fatores, entre os quais as características dos equipamentos, dos veículos e da infraestrutura de transportes (Wohlgemuth, 1997).

Neste contexto, métodos adequados de modelagem são de interesse generalizado entre engenheiros e cientistas, no que diz respeito aos problemas de produção e consumo de energia. Na maioria das vezes, a previsão da demanda por energia é feita com base no consumo histórico e na relação deste consumo com outras variáveis econômicas e demográficas, com indicadores climáticos e de estilo de vida, entre outros. Se, por um lado, a subestimação do consumo pode gerar problemas devastadores para a vida e a economia, por outro, a superestimação poderia conduzir ao desperdício de recursos financeiros (Kankal et. al., 2011). Desta forma, torna-se premente a busca por métodos adequados de previsão e modelagem, não só no tocante aos prejuízos econômicos que podem ser gerados pela má estimativa do consumo de combustíveis, mas também e, principalmente, pela redução dos danos ambientais, uma vez que o CO₂ é o principal gás do efeito estufa. Diante disso, vários trabalhos científicos têm buscado nas ferramentas matemáticas, econométricas, estatísticas e computacionais os recursos para a produção de modelos que forneçam resultados mais realistas, tanto do ponto de vista da estimativa quando da relação entre as variáveis envolvidas nesse tipo de problema.

Desta forma, tendo em vista a pluralidade de fatores e metodologias empregadas em estudos que abordaram o problema do consumo de combustíveis pelo transporte, este trabalho consiste em uma pesquisa qualitativa, de natureza exploratória, na qual será divulgada uma revisão bibliográfica com o objetivo de apresentar as variáveis, os diferentes métodos utilizados e as conclusões obtidas por autores que discutiram o tema. Para tal, a seção 2 apresenta algumas referências, dividindo os métodos utilizados em quatro categorias: estatísticos/econométricos, *soft computing*, abordagem *bottom-up* e simulações. Na seção 3, serão traçadas algumas considerações a respeito dos trabalhos citados.

2. Modelos utilizados para análise da demanda de energia pelo setor de transportes

2.1 Métodos Estatísticos/Econométricos

Dentro dessa categoria, enquadram-se os modelos de Regressão Linear e Não Linear, os métodos para Análise de Séries Temporais, os Modelos de Equações Estruturais, os Testes de Causalidade e os modelos espaço-temporais, dentre outros. Enquanto os modelos que envolvem a Análise de Séries Temporais e os modelos de Regressão permitem realizar previsões, os testes de causalidade têm como objetivo identificar uma relação estatística de causa e efeito entre duas ou mais variáveis quando existe uma relação de precedência temporal entre elas.

Em seu trabalho, Zhang et. al. (2009) propuseram um modelo para prever a demanda por energia em transportes com base no método de Regressão de Mínimos Quadrados Parcial, sob dois cenários. Segundo esses autores, o setor de transportes é responsável por uma parte significativa do consumo de energia na China, principalmente com relação aos produtos derivados de petróleo que vem experimentando rápidos aumentos na demanda. A demanda de energia para o transporte foi analisada para o período 1990 – 2006 com base no GDP, na taxa de urbanização e no volume de negócios com passageiros e fretes. As informações sobre consumo de energia com transporte e volume de negócios com transporte de passageiros e de carga foram medidos em bilhões de pessoas por km e bilhões de toneladas por km, respectivamente.

O trabalho de Birol e Guerer (1993) avaliou a evolução da demanda por petróleo em transporte de seis países (Turquia, Tailândia, Paquistão, Tunísia, Marrocos e Malásia). Os autores utilizaram modelos econométricos e estimaram os consumos de gasolina e óleo diesel separadamente devido à alta proporção de óleo diesel utilizada no setor de transportes desses países. Segundo os autores, tal desagregação é especialmente importante em países em desenvolvimento como um resultado de diferentes padrões de consumo e de políticas de preços, o que pode provocar distorções no cálculo dos preços e taxas. Os resultados deste estudo indicaram que o setor de transportes será a força motriz para a demanda de energia e de petróleo, como parte de crescimento econômico desses países emergentes e que sua participação na estrutura do mercado futuro de energia deve crescer. Em ambos os modelos, foram utilizadas como variáveis dependentes a demanda e como independentes o GDP, o preço real do combustível e valores passados da demanda.

Um modelo de equações simultâneas foi utilizado por Brownstone e Golob (2009), com vistas a analisar o efeito da densidade residencial na quantidade de milhas rodadas e no consumo de combustíveis na Califórnia. As variáveis densidade residencial, uso do veículo e consumo de combustível foram adicionadas como variáveis endógenas e foram incluídas no modelo uma série de variáveis de controle (renda anual domiciliar, número de crianças no domicílio, número de trabalhadores no domicílio, número de motoristas no domicílio, grau de instrução do respondente e raça). Os resultados indicaram que a densidade influencia diretamente a utilização do veículo e tanto densidade quanto uso influenciam no consumo de combustível. As variáveis exógenas mais importantes foram o número de motoristas e o número de trabalhadores no domicílio, embora educação e renda também tenham se mostrado significativas.

Rentzou et. al. (2012) desenvolveram um modelo de equações simultâneas para prever a quantidade de milhas viajadas por veículos nos Estados Unidos. Para tal, foi utilizada a quantidade agregada de milhas viajadas para 48 estados dos Estados Unidos entre os anos 1998 e 2008, sendo que os dados foram desagregados por tipo de rodovia (urbana ou rural). O modelo proposto utilizou três variáveis endógenas (total de milhas viajadas por ano por todos os veículos da frota, total de galões de combustível equivalentes a gasolina usados por ano e número de unidades habitacionais por milha quadrada). Somente carros de passageiros, motocicletas, caminhões leves e ônibus foram considerados no estudo. Como variáveis explicativas, foram utilizadas variáveis demográficas (população, idade, raça) e socioeconômicas (renda, percentual de trabalhadores na casa e densidade). Foram utilizados ainda dados referentes ao custo e taxas relativos aos combustíveis, comprimento das rodovias principais (em milhas), dados sobre veículos que usam combustível alternativo (incluindo gás natural, gás liquefeito natural, gás liquefeito de petróleo, eletricidade, etanol e metanol) e nível de congestionamento, dentre outras. Os resultados observados indicaram a significância dos efeitos de população, raça, gênero, população urbana, renda per capita, número de veículos registrados e densidade. As análises também indicam que a quantidade de milhas viajadas é inelástica com relação aos custos e taxas sobre os combustíveis e que o efeito das telecomunicações e da quantidade de veículos com combustíveis alternativos é significativo. Em adição, os autores propuseram uma metodologia para investigar como diferentes políticas governamentais de taxação e a densidade podem afetar o consumo de energia e a emissão de gases, a partir de um modelo de dados de painel com coeficientes aleatórios, que foi utilizado para a construção de cenários futuros.

Segundo Liu (2014), os modelos mais utilizados para modelar a demanda por gasolina é o modelo log-linear, em que o consumo de gasolina é modelado a partir do preço da gasolina e da renda. Neste modelo, o log é aplicado em todas as variáveis e os coeficientes obtidos para o preço da gasolina e a renda podem ser diretamente interpretados como a elasticidade do preço e a elasticidade da renda, respectivamente. De acordo com o autor, o principal problema deste tipo de modelo diz respeito à suposição de uma relação estritamente linear entre a demanda e as variáveis exploratórias, o que implica no fato de que as demandas estimadas sejam homogêneas para toda a amostra. Esse comportamento, segundo o autor, é questionável, uma vez se espera que as elasticidades de preço e renda na demanda por gasolina sejam heterogêneas em diferentes regiões, devido a vários fatores tais como temperaturas, regulamentação e estilos de dirigir. Segundo o mesmo autor, outro tipo de modelo utilizado para este tipo de problema é o modelo *translog*, que inclui termos quadráticos do preço da gasolina e renda, além de um fator de interação entre essas duas variáveis. Sob esta abordagem, as elasticidades da renda e do preço podem ser derivadas como funções lineares do preço da gasolina e da renda. Entretanto, o preço da gasolina e a renda não são as únicas fontes que podem causar heterogeneidade nas elasticidades da demanda. O mesmo aumento no preço da gasolina pode causar reações diferentes em moradores das zonas urbanas e rurais, por exemplo, o que poderia sugerir a inclusão de um termo de interação entre preço da gasolina e localização, o que provocaria a perda de graus de liberdade. Diante disso, o autor propõe uma abordagem semiparamétrica para modelar a demanda por gasolina nos Estados Unidos. Este tipo de modelo permite que os coeficientes sejam funções suaves não paramétricas de uma classe de atributos, que incluem a taxa de desemprego, a densidade populacional, o investimento do estado no trânsito, o percentual de caminhões e o ano.

Li et. al. (2010) compararam oito abordagens distintas (modelo de tendência linear, modelo de tendência quadrática, modelo de alisamento exponencial simples, modelo linear de Holt, modelo linear de Holt-Winters, modelo de ajustamento parcial e modelo ARIMA) para prever o consumo de petróleo na Austrália. Foram utilizadas no estudo séries trimestrais de dados, incluindo o consumo de combustível nas rodovias, o GDP e o preço real do petróleo desde o primeiro trimestre de 1974 até o quarto trimestre de 2006. Os resultados obtidos por eles indicaram que o modelo que teve melhor desempenho na previsão de dados sazonais foi o de tendência quadrática, enquanto para dados não sazonais, o mesmo tipo de modelo foi o que produziu melhores previsões de curto prazo.

Com o objetivo de testar a relação entre densidade urbana e a demanda por combustíveis, além de explicitar as elasticidades estimadas da demanda de combustíveis com respeito à densidade urbana, Karathodorou et. al. (2010) utilizaram dados de 84 cidades provenientes de 42 países diferentes. Para representar a densidade urbana, foram utilizados dados agregados por cidade e a demanda por combustível per capita foi decomposta como o produto da propriedade de veículos per capita, o consumo de combustíveis por quilometro e a distância percorrida por carro anualmente, com cada componente especificada como uma função da densidade urbana. Modelos para os três componentes foram então estimados individualmente usando Mínimos Quadrados Ordinários e simultaneamente utilizando o modelo SURE (Seemingly Unrelated Regression Equations). As variáveis explicativas utilizadas foram densidade, GDP, preço dos combustíveis, comprimento das vias por milhares de pessoas, número de assentos oferecidos pelo transporte público, consumo de combustível por quilômetro, comprimento das rodovias, custo médio de uma viagem no transporte público e custo de utilização do carro per capita. Os resultados observados sugerem que a densidade urbana tem um efeito sobre o consumo de combustíveis, principalmente através de variações no estoque de veículos e na distância percorrida, ao invés do consumo de combustível por quilômetro.

Su (2011) utilizou abordagens paramétrica e semiparamétrica com vistas a obter um modelo para o consumo de gasolina nas áreas urbanas dos Estados Unidos. Foram utilizadas como variáveis explicativas a idade, densidade populacional, densidade rodoviária, total de horas de atraso por passageiro, tamanho da área urbana, tarifa de ônibus, disponibilidade de ferrovias, número de motoristas, número de motoristas comerciais, número de idosos e renda, entre outros. O autor conclui que famílias que vivem em áreas urbanas com maior tempo de atraso anual por

viajante em horário de pico ou maior densidade de rodovias em termos de pista por quilometro quadrado consomem mais gasolina, enquanto que as famílias que vivem em áreas urbanas com alta densidade populacional consomem menos gasolina.

Du e Carriquiry (2013) utilizaram um modelo espaço-temporal do tipo hierárquico para avaliar o consumo do etanol derivado do milho nos Estados Unidos e o desenvolvimento do mercado do produto. Eles observaram que além da dependência espacial entre Estados vizinhos, a inclusão diferencial de etanol é altamente determinada pelas políticas de incentivo, tanto em nível estadual quanto nacional, pelo preço relativo da gasolina, pela disponibilidade de matéria-prima, pela renda mediana da família, pela proibição de uso do Éter etil-terc-butílico e pela densidade de infraestrutura na venda ao varejo do combustível.

O Teste de Causalidade de Granger foi a ferramenta utilizada por Liddle e Lung (2013) para analisar a relação de causalidade entre o consumo de energia per capita pelo transporte e o GDP per capita para dados em painel de 107 países, no período 1971-2009. Os dados foram divididos em painéis com base em três níveis de renda, para determinar a direção da causalidade. Como conclusão, esses autores observaram que as relações de causalidade assumiram um comportamento bastante heterogêneo entre os países analisados, sendo que alguns países apresentaram causalidade significativa indo de consumo de energia para o transporte para GDP.

Análise de Causalidade também a ferramenta utilizada no trabalho de Bowden e Payne (2009), que usaram o teste de Toda-Yamamoto para examinar a relação causal de longo prazo entre consumo de energia e GDP, a partir de dados de consumo medidos no período 1949 a 2006 nos Estados Unidos. Além do consumo gerado pelo setor de transportes, também foram avaliados o consumo pelos setores residencial e comercial. As conclusões apontaram ausência de causalidade entre o consumo de energia pelo transporte e GDP.

Os testes de causalidade também foram empregados no trabalho de Samimi (1995) para avaliar a relação entre consumo de energia pelo transporte rodoviário, volume de produção e preços de combustíveis. Como resultados, o autor observou causalidade bidirecional entre produção e consumo de energia e causalidade unidirecional de energia para preços.

2.2 Soft Computing

Soft Computing, também conhecida como computação flexível, é uma área de pesquisa que procura abordar problemas onde existem incertezas e imprecisões. São técnicas que tentam simular o comportamento do cérebro humano e englobam lógica fuzzy, redes neurais, computação evolutiva, sistemas inteligentes e teoria da possibilidade, entre outras.

Dentro dessa categoria, encontra-se o trabalho de Limanond et. al. (2011), que propuseram modelos para projetar o consumo de energia em transportes na Tailândia para um intervalo de 20 anos. Como ferramentas, foram utilizadas as Redes Neurais Artificiais e o Modelo de Regressão Log-linear. Como variável dependente, estes autores utilizaram a demanda de energia em transportes (em unidades de milhões de toneladas equivalentes de petróleo – Mtoe). Como variáveis independentes, foram utilizados o GDP nacional, a população e o número de veículos registrados. Na ausência de atividades de viagens, uma vez que as agências locais não possuem dados sobre a quilometragem rodada pelos veículos, os autores utilizaram o número de veículos registrados como um substituto, com base no pressuposto de que quanto maior o número de veículos registrados, maior a atividade veicular. O número de veículos registrados foi dividido em três categorias, de acordo com o consumo: pequeno porte (incluindo motocicletas), veículos médios (incluindo carros de passageiros, vans, pick-ups) e veículos de grande porte (incluindo ônibus, caminhões e *trailers*). O modelo foi ajustado a partir de uma série histórica de 20 anos (1989-2008). Os autores afirmam que o GDP possui uma relação direta com o consumo de energia em transportes e concluíram que a atividade veicular talvez seja um dos fatores mais influentes na demanda por energia. Em adição, o trabalho traz um apanhado de técnicas e variáveis utilizadas em alguns trabalhos que fizeram projeções do consumo de energia com transportes.

Al-Ghandoor et. al. (2012) utilizaram um Sistema de Inferência Neuro-Fuzzy Adaptativo (ANFIS) e a técnica de duplo alisamento exponencial para desenvolver um modelo de

previsão para a demanda de energia por transporte na Jordânia. Para o modelo ANFIS, foram utilizadas variáveis socioeconômicas e indicadores relacionados ao transporte, tais como o número de veículos, o número de proprietários de veículos (número de carros/número de habitantes), o nível de renda e preços de combustíveis. Os resultados apresentados pelos modelos indicam que a demanda de energia por transporte tem um aumento previsto de 4,9% ao ano entre os anos 2010 e 2030. Al-Ghandoor (2013) associa o modelo de séries temporais àquele obtido no trabalho publicado em 2012 e faz a construção de cenários nos quais avalia os impactos no consumo de energia e na redução das emissões de CO₂ promovidos pelo setor de transportes com o aumento do número de carros com motores a diesel em substituição aos que utilizam óleo cru.

Além de variáveis socioeconômicas (densidade populacional, número de empregos e renda, entre outros), os trabalhos de Costa (2001) e Silva et. al. (2007) utilizaram variáveis relativas à forma urbana para estimar a energia consumida em transportes para o Estado de São Paulo e também para capitais dos Estados brasileiros. Como ferramentas, foram utilizadas as Redes Neurais Artificiais e um Sistema de Informações Geográficas. Os resultados observados nestes estudos indicaram a influência da densidade populacional e da população tanto para o Estado de São Paulo quanto para as capitais analisadas. Para o Estado de São Paulo, ainda foram influentes o nível de empregos no comércio, o grau de escolaridade e a percentagem de vias pavimentadas. Para as capitais brasileiras, além da densidade e da população, a frota de veículos automotores foi considerada influente. Metodologia semelhante foi utilizada por Costa (2003), para Portugal. Os resultados obtidos nesse trabalho confirmaram a influência das características da forma urbana e a distribuição da população no consumo de energia em transportes, assim como do número de pessoas empregadas em vários ramos de atividades.

O trabalho de Coelho (2007) apresentou um modelo baseado em lógica fuzzy, que tinha por objetivo prever a evolução da produção de biodiesel no Brasil até o ano de 2011, a partir de uma série temporal de dados de consumo e com a inclusão do preço do petróleo, da redução dos gases do efeito estufa, tecnologia e incentivos como variáveis de entrada. Os resultados obtidos indicaram que o preço do petróleo é a variável mais determinante na produção do combustível.

Haldenbilen e Ceylan (2005) propuseram um modelo baseado em algoritmos genéticos e utilizaram dados sobre população, GDP e quilometragem rodada para prever a demanda de combustíveis pelo setor de transportes da Turquia. Como resultado, eles observaram que o modelo que envolveu uma relação não linear foi o que melhor explicou a relação entre a variável dependente e as independentes.

2.3 Abordagem *Bottom-up*

O objetivo da abordagem *bottom-up* é o de juntar sistemas menores para dar origem a sistemas maiores, transformando os sistemas originais em subsistemas do sistema emergente. Dentro deste tipo de abordagem, pode-se destacar o modelo MARKAL, desenvolvido para estudar o problema da demanda e suprimento de energia (Suganthi e Samuel, 2012).

De acordo com Muratori et. al. (2013), os modelos do tipo *bottom-up* fornecem dados de alta resolução, sem a necessidade de confiar em dados históricos, fornecendo a habilidade de modelar o impacto de diferentes tecnologias e permitindo a implementação de gerenciamento de energia e técnicas de otimização. Eles utilizaram uma aproximação através de Cadeias de Markov para modelar o comportamento de motoristas norte-americanos. O modelo gera um padrão de atividade para cada indivíduo incluído na simulação. Esses perfis são uma representação da sequência de tempo das atividades executadas pelos motoristas típicos do país. Eles concluíram que a relação entre a duração ou distância da viagem e o perfil de direção dos indivíduos dependem de uma grande quantidade de fatores pessoais e físicos, tais como estilo de dirigir, temperatura ambiente, desempenho do veículo e condições da via.

Com o objetivo de incluir fatores psicossociais nos modelos de previsão de demanda por energia, Anable et. al. (2012) propõem uma metodologia de construção de cenários futuros a partir do uso do Modelo de Demanda Elástica de MARKAL (MED – MARKAL Elastic Demand).

Outro trabalho que incorporou o estilo de vida na modelagem foi o realizado por Moraes (2005), que utilizou o modelo MAED (Model for Analysis of Energy Demand) para realizar uma projeção da demanda de combustíveis para o setor de transportes brasileiro no período de 2000 a 2025. O modelo proposto utilizou variáveis demográficas (população, população em áreas urbanas), econômicas (PIB, agricultura, construção, mineração, manufatura, energia e serviços) e relativas ao estilo de vida (posse de veículos, distância média ao transporte urbano, distância média no transporte interurbano).

2.4 Simulações

O objetivo da simulação é prever o comportamento de um sistema, com várias entradas, a partir de premissas previamente estabelecidas. Normalmente, um problema de simulação é formado através de uma problemática assumida, em respeito aos dados de entrada e hipóteses que delimitem as variáveis de saída (Tadeu, 2010).

O Método de Simulação de Monte Carlo associado à Programação Linear foi utilizado por Tadeu (2010) com o objetivo de prever o consumo de combustíveis pelo setor de transportes brasileiro e para projetar possíveis cenários de longo prazo, construídos com vistas a maximizar e minimizar o PIB nacional e o PIB setorial. Para tal, utilizou-se dados da frota, preços dos combustíveis, demanda e consumo de combustíveis e variáveis econômicas. Os resultados observados indicam uma variação nas estimativas dos valores de demanda e consumo de combustíveis. Segundo o autor, essa variação depende das políticas públicas para crescimento econômico, nos preços praticados a longo prazo.

Outro trabalho que utilizou o Método de Simulação de Monte Carlo foi o proposto por Bastani et. al. (2012), que utilizaram o modelo STEP (Stochastic Transport Emissions Policy) para quantificar as emissões e o uso de combustíveis provocados pela frota dos Estados Unidos. Os resultados obtidos mostram a distribuição de probabilidade do nível das emissões, do uso de combustíveis e do consumo de energia até o ano 2050. O modelo identificou e classificou por ordem os parâmetros mais influentes nas variações das emissões e do consumo, verificando que os mesmos variam com o tempo. Dentre esses parâmetros, pode-se citar: taxa de sucateamento dos veículos, crescimento anual das distâncias viajadas, venda total de veículos, economia de combustível, percentual de gasolina substituída por etanol, dentre outros.

Lindsay et. al. (2011) também utilizaram simulações para construir cenários com vistas a investigar a relação entre a localização e quantidade de milhas viajadas domiciliar, consumo de energia e emissões de CO₂ associados com o uso de veículos privados em Chicago, a partir de dados coletados no período 2007 – 2008. Como resultados, eles concluem que a quantidade de milhas viajadas, o consumo de energia e as emissões de CO₂ aumentam com a distância aos centros de negócios e decrescem com a densidade residencial. Também concluem que um aumento na eficiência da frota veicular pode amenizar os efeitos das distância no consumo.

Com o objetivo de estimar a contribuição do setor de aviação para as mudanças climáticas, Alonso et. al. (2014) apresentaram previsões para o crescimento do transporte aéreo, para a demanda por energia proveniente de combustíveis e para a evolução da utilização de combustíveis alternativos para 27 países da União Europeia, incluindo a Suíça e a Noruega. Como variáveis para o estudo, foram utilizados o número de voos comerciais para transporte de passageiros, o número total de passageiros embarcados, o número total de assentos disponíveis, total de frete e de voos do correio aéreo comercial global, frete total e correspondências embarcadas em toneladas. Os resultados indicaram uma projeção do consumo total de combustíveis (incluindo bioquerosene) para o ano de 2030 na ordem de 93, 66 e 106 milhões de toneladas, considerando-se os cenários de continuação de tendência, pessimista e otimista, respectivamente. Com vistas a apresentar, de forma sumarizada, as técnicas e as variáveis utilizadas pelos autores mencionados anteriormente, foi construída a Tabela 1.

Tabela 1 – Quadro resumo.

	Autores	País de estudo	Variáveis envolvidas	Método
Métodos Estatísticos e/ou Econométricos	Zhang et. al. (2009)	China	Demanda de energia pelo transporte, taxa de urbanização e volume de negócios com passageiros e fretes	Regressão de Mínimos Quadrados Parcial
	Birol e Guerer (1993)	Turquia, Tailândia, Paquistão, Tunísia, Marrocos e Malásia	Demanda por petróleo, GDP, preço real do combustível e valores passados da demanda.	Modelos Econométricos – modelo de ajustamento parcial
	Brownstone e Golob (2009)	Estados Unidos	Densidade residencial, utilização de veículo, consumo de combustível, renda anual domiciliar, número de crianças no domicílio, número de trabalhadores no domicílio, número de motoristas no domicílio, grau de instrução do respondente e raça.	Modelo de equações simultâneas
	Rentzou et. al. (2012)	Estados Unidos	Total de milhas viajadas por ano por todos os veículos da frota, total de galões de combustível equivalentes a gasolina usados por ano, número de unidades habitacionais por milha quadrada, população, idade, raça, renda, percentual de trabalhadores na casa, densidade, custos e taxas relativos aos combustíveis, número de milhas das rodovias principais, dados sobre veículos que usam combustível alternativo e nível de congestionamento	Modelo de equações simultâneas
	Liu (2014)	Estados Unidos	Taxa de desemprego, densidade populacional, investimento do estado no trânsito, percentual de caminhões e ano	Abordagem semiparamétrica
	Li et. al. (2010)	Austrália	Demanda por petróleo, consumo de combustível nas rodovias, GDP e preço real do petróleo	Modelo de tendência linear, modelo de tendência quadrática, modelo de alisamento exponencial simples, modelo linear de Holt, modelo linear de Holt-Winters, modelo de ajustamento parcial e modelo ARIMA
	Karathodorou et. al. (2010)	Cidades de 42 países	Propriedade de veículos per capita, consumo de combustíveis por quilometro, distância percorrida por carro anualmente, densidade, GDP, preço dos combustíveis, comprimento das vias por milhares de pessoas, número de assentos oferecidos pelo transporte público, comprimento das rodovias, custo médio de uma viagem no transporte público e custo de utilização do carro per capita	Regressão Linear Múltipla e modelo SURE
	Su (2011)	Estados Unidos	Consumo de gasolina, idade, densidade populacional, densidade rodoviária, total de horas de atraso por passageiro, tamanho da área urbana, tarifa de ônibus, disponibilidade de ferrovias, número de motoristas, número de motoristas comerciais, número de idosos e renda, entre outros.	Regressão paramétrica e semiparamétrica.
	Du e Carriquiry (2013)	Estados Unidos	Consumo de etanol, medida de dependência espacial, preço relativo da gasolina, políticas de incentivo em nível estadual (taxas), produção de milho, emprego na indústria de óleo e gás, renda mediana domiciliar e cronograma estadual de proibição de uso do Éter etil-terc-butílico	Modelo espaço-temporal do tipo hierárquico
	Liddle e Lung (2013)	Dados de 107 países	Consumo de energia pelo transporte e GDP	Tstes de Causalidade de Granger
	Bowden e Payne (2009)	EUA	GDP e consumo de energia pelos setores de transporte, residencial e comercial	Teste de Causalidade de Toda-Yamamoto
Samimi (1995)	Austrália	Consumo de energia pelo transporte rodoviário, volume de produção e preços de combustíveis	Testes de causalidade	
Abordagem bottom-up	Anable et. al. (2012)	Reino Unido	Nível de emissões de carbono, GDP, distância média percorrida, ocupação média do veículo, modo, eficiência, crescimento da demanda pelo transporte aéreo, tecnologia (propulsão)	Modelo de Demanda Elástica de MARKAL (MED – MARKAL Elastic Demand)
	Muratori et. al. (2013)	Estados Unidos	Duração da viagem, estilo de dirigir, temperatura ambiente, desempenho do veículo e condições da via	Cadeias de Markov

	Moraes (2005)	Brasil	Demanda de combustíveis para o setor de transportes, população, população em áreas urbanas, PIB, agricultura, construção, mineração, manufatura, energia, posse de veículos, distância média ao transporte urbano, distância média no transporte interurbano.	MAED (Model for Analysis of Energy Demand)
Soft computing	Limanond et. al. (2011)	Tailândia	Demanda de energia pelo transporte, GDP, população e atividade veicular (medida através do número de veículos registrados)	Redes Neurais Artificiais e Modelo de Regressão Log-linear
	Al-Ghandoor et. al. (2012) Al-Ghandoor et. al. (2013)	Jordânia	Demanda de energia pelo transporte, número de veículos, número de proprietários de veículos (número de carros/número de habitantes), nível de renda e preços de combustíveis	Sistema de Inferência Neuro-Fuzzy Adaptativo (ANFIS) e duplo alisamento exponencial
	Costa (2001), e Silva et. al. (2007)	Brasil	Energia consumida em transportes, forma urbana, densidade populacional, número de empregos e renda, entre outros	Redes Neurais Artificiais e Sistemas de Informações Geográficas
	Costa (2003)	Portugal	Energia consumida em transportes, forma urbana, densidade populacional, número de empregos e renda, entre outros	Redes Neurais Artificiais e Sistemas de Informações Geográficas
	Coelho (2007)	Brasil	Série Temporal de dados de produção de Biodiesel, preço do petróleo, da redução dos gases do efeito estufa, tecnologia e incentivos.	Lógica Fuzzy
	Haldenbilen e Ceylan (2005)	Turquia	Demanda de combustíveis pelo transporte, população, GDP e quilometragem rodada	Algoritmos Genéticos
Simulações	Tadeu (2010)	Brasil	Consumo de combustíveis, dados da frota, preços dos combustíveis, demanda e consumo de combustíveis e variáveis econômicas	Simulação de Monte Carlo / Programação Linear
	Bastani et. al. (2012)	Estados Unidos	Nível de emissões, uso de combustíveis, consumo de energia, taxa de sucateamento dos veículos, crescimento anual das distâncias viajadas, venda total de veículos, economia de combustível, percentual de gasolina substituída por etanol.	Modelo STEP (Stochastic Transport Emissions Policy)
	Alonso et. al. (2014)	Países da União Européia	Crescimento do transporte aéreo, demanda por energia proveniente de combustíveis, evolução da utilização de combustíveis alternativos, número de voos comerciais para transporte de passageiros, número total de passageiros embarcados, número total de assentos disponíveis, total de frete e de voos do correio aéreo comercial global, frete total e correspondências embarcadas em toneladas	Construção de cenários a partir de simulações
	Lindsay et. al. (2011)	Estados Unidos	Localização e quantidade de milhas viajadas domiciliar, consumo de energia e emissões de CO ₂ associados com o uso de veículos privados, número de usuários de trânsito no domicílio, estudantes que vão a pé ou de bicicleta para a escola, motoristas licenciados, veículos, ocupantes, trabalhadores, estudantes e renda familiar.	Simulações de cenários

3. Considerações Finais

Pode-se observar que os trabalhos analisados utilizaram uma vasta gama de variáveis explicativas em suas análises. O GDP aparece com frequência nesses estudos, assim como dados sobre população e renda. Vários modelos envolvem estilo de vida e fatores socioculturais, além de dados acerca da forma urbana. Em grande parte dos trabalhos, a informação foi obtida junto a órgãos oficiais.

Com relação às técnicas empregadas, observou-se que o problema foi abordado a partir de vários métodos distintos e que muitas vezes, os autores fizeram uso combinado de mais de uma técnica. Há uma predominância de métodos estatísticos e/ou econométricos, sendo que muitas vezes os resultados fornecidos por estes modelos e outras técnicas foram confrontados nas análises. Em alguns destes estudos, foi observado que técnicas de *soft computing*, tais como Redes Neurais Artificiais e Sistemas envolvendo Lógica Fuzzy apresentaram resultados iguais ou superiores aos modelos convencionais para realizar previsões.

Testes de causalidade também apareceram com frequência em trabalhos sobre demanda de energia, tanto pelo transporte quanto para outros setores de economia (Tiwari, 2014; Payne, 2009; Bowden e Payne, 2010; Esseghir e Khouri, 2014; Warr e Ayres, 2010; Soyta et. al., 2007;

Kum et. al., 2012). A maioria destes trabalhos buscam estabelecer uma relação de causalidade entre GDP e consumo e o que chama a atenção é o fato de que os testes realizados apresentam resultados contraditórios. Muitos dos estudos concluíram ausência de causalidade entre o consumo de energia e GDP, enquanto outros concluíram que o consumo causa o GDP e outros concluem que GDP causa consumo. Esse fato também foi observado por Ajmi et. al. (2013), após uma ampla revisão bibliográfica acerca da relação de causalidade entre GDP e consumo de energia para os países do G7. Cabe ressaltar que, embora os testes de causalidade indiquem um caminho para analisar as relações entre as variáveis envolvidas, eles não têm por foco o fornecimento de um modelo de previsão. Entretanto, ao se tratar com séries temporais de dados, torna-se necessário estabelecer a relação de precedência temporal entre as variáveis envolvidas.

Agradecimentos

Os autores agradecem à FAPESP e à Fundação Araucária pelo apoio financeiro.

Referências

- Ajmi, A. N., Montasser, G. E. e Nguyen, D. K. (2013). Testing the relationships between energy consumption and income in G7 countries with nonlinear causality tests, *Economic Modelling*, 35, 126–133.
- Al-Ghandoor, A. (2013). An approach to energy savings and improved environmental impact through restructuring Jordan's transport sector, *Renewable and Sustainable Energy Reviews*, 18, 31–42.
- Al-Ghandoor, A., Samhour, M., Al-Hinti, I., Jaber, J. e Al-Rawashdeh, M. (2012). Projection of future transport energy demand of Jordan using adaptive neuro-fuzzy technique, *Energy*, 38, 128 - 135.
- Alonso, G., Benito, A., Lonza, L. e Kousoulidou, M. (2014). Investigations on the distribution of air transport traffic and CO₂ emissions within the European Union, *Journal of Air Transport Management*, 36, 85 – 93.
- Anable, J., Brand, C., Tran, M. e Eyre, N. (2012) Modelling transport energy demand: A socio-technical approach, *Energy Policy*, 41, 125–138.
- Bastani, P., Heywood, J. B. e Hope, C. (2012). The effect of uncertainty on US transport-related GHG emissions and fuel consumption out to 2050, *Transportation Research Part A*, 46, 517–548.
- Biol, F. e Guerer, N. Modelling the transport sector fuel demand for developing economies (1993), *Energy Policy*, 1163 – 1172.
- Bölük, G. e Mert, M. (2014). Fossil & renewable energy consumption, GHGs (greenhouse gases) and economic growth: Evidence from a panel of EU (European Union) Countries, *Energy*, 74, 439 – 446.
- Bowden, N. e Payne, J. E. (2009). The causal relationship between U. S. energy consumption and real output: A disaggregated analysis, *Journal of Policy Modeling*, 31, 2, 180-188.
- Bowden, N. e Payne, J. E. (2010). Sectoral Analysis of the Causal Relationship Between Renewable and Non-Renewable Energy Consumption and Real Output in the US, *Energy Sources, Part B: Economics, Planning, and Policy*, 5, 4, 400-408.
- Brownstone, D. e Golob, T. F. (2009) The impact of residential density on vehicle usage and energy consumption, *Journal of Urban Economics*, 65, 91–98.
- Coelho, B. F. V. M. (2007). Modelo de Previsão da Evolução do Biodiesel no Brasil Utilizando Lógica Fuzzy. (Dissertação). Faculdade de Economia e Finanças IBMEC - Programa de pós-graduação e pesquisa em Administração e Economia. 43 p.
- Costa, G. C. F. (2001) Uma avaliação do consumo de energia com transportes em cidades do Estado de São Paulo. (Dissertação). Programa de Pós-graduação em Engenharia de Transportes. 103 p.
- Costa, P. T. (2003). Uma análise do consumo de energia em transportes nas cidades portuguesas utilizando Redes Neurais Artificiais. (Dissertação). Departamento de Engenharia Civil. Universidade do Minho. 133p.
- Du, X. e Carriquiry, M. A. (2013). Spatio temporal analysis of ethanol market penetration, *Energy Economics*, 38, 128–135.

- Esseghir, A. e Khouni, L. H.** (2014). Economic growth, energy consumption and sustainable development: The case of the Union for the Mediterranean countries, *Energy*, 71, 218 – 225
- Haldenbilen, S. e Ceylan, H.** (2005) Genetic Algorithm approach to estimate transport energy demand in Turkey, *Energy Policy*, 33, 1, 89-98.
- Kankal, M., Akpinar, A., Kömürcü, M. I. e Özşahin, T. S.** (2011). Modeling and forecasting of Turkey's energy consumption using socio-economic and demographic variables, *Applied Energy*, 88, 1927–1939.
- Karathodorou, N., Graham, D. J. e Noland, R. B.** (2010). Estimating the effect of urban density on fuel demand, *Energy Economics*, 32, 86–92.
- Kum, H., Ocal, O. e Aslan, A.** (2012). The relationship among natural gas energy consumption, capital and economic growth: Bootstrap-corrected causality tests from G-7 countries, *Renewable and Sustainable Energy Reviews*, 16, 2361– 2365.
- Li, Z., Rose, J. M. e Hensher, D. A.** (2010). Forecasting automobile petrol demand in Australia: An evaluation of empirical models, *Transportation Research Part A*, 44,16–38.
- Liddle, B. e Lung, S.** (2013), The long-run relationship between transport energy consumption and GDP: Evidence from heterogeneous panel methods robust to cross-sectional dependence, *Economic Letters*, 121, 3, 524-527.
- Limanond, T., Jomnonkwo, S. e Srikaew, J.** (2011) Projection of future transport energy demand of Thailand, *Energy Policy*, 39, 2754–2763.
- Lindsey, M., Schofer, J. L., Durango-Cohen, P. e Gray, K. A.** (2011). The effect of residential location on vehicle miles of travel, energy consumption and greenhouse gas emissions: Chicago case study, *Transportation Research Part D*, 16, 1–9.
- Liu, W.** (2014). Modeling gasoline demand in the United States: A flexible semiparametric approach, *Energy Economics*, 45, 244–253.
- Moraes, N. G.** (2005). Avaliação das Tendências da Demanda de Energia no Setor de Transportes no Brasil. (Dissertação). Universidade Federal do Rio de Janeiro, COPPE. 167 p.
- Muratori, M., Moran, M. J., Serra, E. e Rizzoni, G.** (2013). Highly-resolved modeling of personal transportation energy consumption in the United States, *Energy*, 58, 168-177.
- Naess, P.** (2012). Urban form and travel behavior: Experience from a Nordic context, *The Journal of Transport and Land Use*, 5, 2, 21-45.
- Payne, J. E.** (2009). On the dynamics of energy consumption and output in the US, *Applied Energy*, 86, 575–577.
- Rentziou, A., Gkritza, C. e Souleyrette, R. R.** (2012). VMT, energy consumption, and GHG emissions forecasting for passenger transportation, *Transportation Research Part A*, 46, 487–500.
- Samimi, R.** (1995). Road transport energy demand in Australia – a cointegration approach, *Energy Economics*, 17, 4, 329-339.
- Silva, A. N. R., Costa, G. C. F. e Brondino, N. C. M.** (2007). Urban sprawl and energy use for transportation in the largest Brazilian Cities, *Energy for Sustainable Development*, 11, 3, 44 – 50.
- Su, Q.** (2011). The effect of population density, road network density, and congestion on household gasoline consumption in U.S. urban áreas, *Energy Economics*, 33, 445-452.
- Suganthi, L. e Samuel, A.** (2012) Energy models for demand forecasting—A review, *Renewable and Sustainable Energy Reviews*, 16, 1223– 1240.
- Tadeu, H. F. B.** (2010) Cenários de Longo Prazo para o Setor de Transportes e Consumo de Combustíveis. (Tese). Programa de Pós-Graduação em Engenharia Mecânica da Pontifícia Universidade Católica de Minas Gerais. 227 p.
- Tiwari, A. K.** (2014). The asymmetric Granger-causality analysis between energy consumption and income in the United States, *Renewable and Sustainable Energy Reviews*, 36, 362–369.
- Warr, B.S e Ayres, R.U.** (2010). Evidence of causality between the quantity and quality of energy consumption and economic growth, *Energy*, 35, 1688–1693.
- Wohlgemuth, N.** (1997) World transport energy demand modelling - Methodology and elasticities, *Energy Policy*, 25, 5, 1109-1119.
- Zhang, M., Mu, H., Li, G. e Ning, Y.** (2009). Forecasting the transport energy demand based on PLSR method in China, *Energy*, 34, 1396–1400.