



Grupo de Estudo de Planejamento de Sistemas Elétricos-GPL

Projeção de mercados de energia através de técnicas aprendizagem colaborativa : enfrentando o desafio da escassez de dados

**LEONTINA PINTO(1); ROBINSON SEMOLINI(2); JACQUES SZCZUPAK(3);
ENGENHO(1);ELEKTRO(2);ENGENHO(3);**

RESUMO

Este trabalho enfrenta um grande desafio do setor: a projeção de cenários de carga e mercado que contempla a rápida evolução no comportamento do consumidor. Os novos paradigmas, que se sucedem em velocidade vertiginosa, transformam o histórico passado em dados obsoletos e exigem que o aprendizado se realize com base em comportamentos quase que mutantes, baseados em novas variáveis explicativas e novos padrões de consumo. O enfrentamento deste desafio exige a construção de um conjunto de informações para a aprendizagem a partir de pouquíssimos dados, insuficientes para a aplicação de modelos clássicos baseados em estatística ou redes neurais. Nossa proposta é a utilização de técnicas de aprendizagem colaborativa, capazes de unir os históricos (mesmo que muito recentes) de várias distribuidoras (que apresentem comportamento semelhante), enriquecendo o entendimento do processo e a modelagem do consumidor. Os resultados obtidos são extremamente promissores, e permitem uma assertividade que até agora pareceria impossível: uma projeção segura e confiável a partir de meros doze meses de observações.

PALAVRAS-CHAVE

Projeção de Cenários, Projeção de Mercado, Projeção de Carga, Aprendizagem Colaborativa, Multi-task learning,

1.0 - INTRODUÇÃO

A demanda de energia é talvez o pilar mais importante do mercado: todas as instituições, agentes e processos – desde o planejamento e operação até à comercialização e gestão organizam-se, em última análise, para atendê-la. Pode-se dizer que a projeção de sua evolução futura é crucial para um suprimento econômico e seguro. No entanto, este é um dos maiores desafios atuais. O comportamento do consumidor muda a cada momento, e sucedem-se as reações a diversos estímulos – desde preços a indicadores econômicos, passando inclusive por expectativas e percepções nem sempre baseadas na realidade.

O ano de 2018 vivenciou uma elevação anômala do consumo em todo o Brasil, quase sempre sem respaldo das relações clássicas com o PIB (que experimentou uma queda acentuada) e com a elasticidade da demanda. Enfrentamos um desafio de envergadura: o comportamento do consumidor mudou, e o histórico antigo não representa mais o presente. Na verdade, neste contexto, quanto mais longo o histórico, pior a previsão. Praticamente todas as distribuidoras Brasil.

É necessário o desenvolvimento de modelos matemáticos e ferramentas computacionais tão ágeis quanto o

consumidor, capazes de acompanhá-lo e entendê-lo em tempo real, com a velocidade dos novos tempos.

2.0 - OBJETIVO

O objetivo deste artigo é apresentar um modelo capaz de acomodar mais que a simples escassez de dados: buscamos a extrema escassez, onde a previsão precisa ser realizada a partir de pouquíssimas observações – por exemplo, um ou dois anos. É importante notar que nossa meta não é simplesmente oferecer mais um modelo para a projeção, baseado em uma técnica mais elegante ou moderna. Ao contrário, é necessário desenvolver um modelo para resolver um problema em aberto, onde a escassez de informações é tão grande que inviabiliza a aplicação das técnicas clássicas disponíveis.

Para tanto, propomos a utilização das técnicas de aprendizagem colaborativa (Multi-task learning, ou MLT) não a uma distribuidora apenas, mas a um conjunto de distribuidoras com comportamentos semelhantes. A Aprendizagem colaborativa permite a união das informações de todas as empresas em um único histórico, mais rico e populoso, sem a perda das particularidades de cada uma.

3.0 - CONCEITOS GERAIS

3.1 A modelagem da Variável em Estudo

De forma geral, o objetivo da projeção é a construção de uma função (um modelo) que associa (transforma) um conjunto de variáveis explicativas (entrada) à variável alvo (ou explicada). A Figura 1 apresenta o esquema de projeção da Carga de uma distribuidora e a construção do modelo associado.

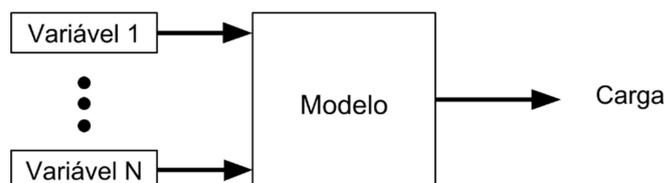


FIGURA 1 – Modelagem da Carga em função de suas variáveis explicativas

Normalmente o Modelo é construído a partir das observações disponíveis – neste caso, o histórico de carga e das variáveis explicativas utilizadas.

Deve-se notar, entretanto, que se todo o histórico fosse utilizado para construir o modelo, não seria possível aferir sua qualidade. Costuma-se assim dividir o histórico disponível em duas partes: as informações para a *identificação* (que serão utilizadas para construir o modelo) e as informações utilizadas para a *validação* (que serão utilizadas para avaliar a sua qualidade). A Figura 2 ilustra o processo para o histórico mensal da Carga da Coelba, explicada pelo PIB, dividido nos períodos de identificação (jan/1995 a dez/2015) e validação (jan/2016 a dez/2018)

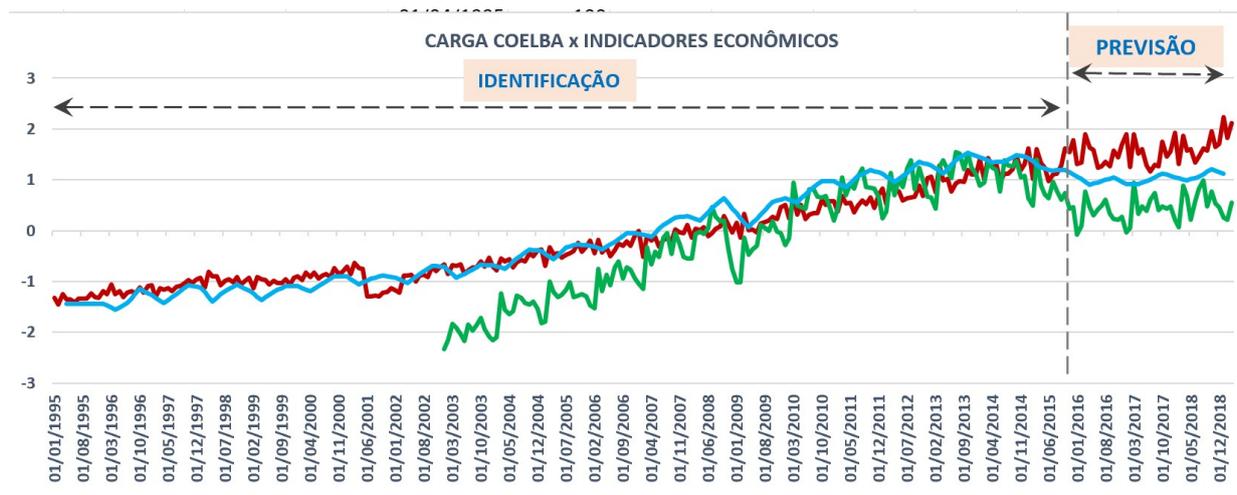


FIGURA 2 – Histórico normalizado da evolução da Carga da Coelba x indicadores econômicos, identificação e validação

É possível notar que o antigo padrão Carga x PIB, ou mesmo Carga x Atividade Econômica não mais se verifica a partir de 2016. Este fenômeno é ainda mais acentuado a partir de 2018: enquanto o PIB sofre uma queda sustentada, a carga parece tomar um impulso não observado nos anos anteriores. Entretanto, a utilização de apenas um ou dois anos históricos torna extremamente difícil – ou mesmo impossível – a aplicação criteriosa de modelos clássicos de identificação. Como extrair informação confiável de um histórico que mal evidencia uma mudança? Como saber se não foi apenas uma anomalia pontual, ou mesmo um erro de medições?

Vale notar que não é possível “criar” informação – em outras palavras, a geração de novos pontos a partir de um histórico limitado (por técnicas de sorteios, ou quaisquer outras) pode produzir *pontos*, mas não *informação* não disponível. Este recurso levaria à distorção da informação (gerando anomalias inconsistentes) ou à mera repetição dos dados existentes, sem qualquer enriquecimento para o modelo.

3.2 A Aprendizagem Colaborativa

Não se pode extrair mais informação de um histórico além da disponível. No entanto, é possível combinar experiências similares, observações de outras distribuidoras que exibem comportamentos semelhantes. Por exemplo, é possível que distribuidoras em regiões próximas, como a COELBA e CELPE e a COSERN, compartilhem da mesma dinâmica do consumo. Neste caso, poderia ser interessante combinar as experiências de cada uma em um único histórico, mais rico e completo.

Esta é a proposta da aprendizagem colaborativa (Multi-task learning, MTL) [1-3]. Ao unir forças, compartilham-se informações sem perder a individualização. O modelo deverá selecionar a dinâmica comum e apontar especificidades, levando a uma projeção mais consistente e confiável.

4.0 - A APRENDIZAGEM COLABORATIVA

Por suas limitações de espaço, este artigo resume o modelo de aprendizagem colaborativa utilizado. A formulação mais detalhada pode ser encontrada em [3]

A literatura técnica na área estabelece um conjunto de saídas ou *tarefas* \mathbf{t} (em nosso caso, as variáveis-alvo, cargas ou consumo). Cada uma destas tarefas é associada a um conjunto de variáveis explicativas (entradas) \mathbf{x} (em nosso caso, atividades econômicas, climáticas, comportamentais, etc.). A hipótese básica requerida pela aprendizagem colaborativa é que as saídas \mathbf{t} reagem de forma semelhante às entradas \mathbf{x} .

A função que “mapeia” a entrada \mathbf{x} à saída \mathbf{t} é escrita como

$$f_t(x) = \sum_{i=1}^d a_{it} u_i(x) : \forall t \in T; a_{it} \in R; x \in R^d \quad (1)$$

onde: \mathbf{x} é a entrada do modelo e $f_t(x)$ é a saída correspondente à tarefa t . A função $u_i(x)$ calcula as *características comuns* entre a entrada \mathbf{x} e as diversas tarefas t e a_{it} mede o “acoplamento” entre as tarefas.

Por simplicidade, assumiremos funções lineares. Neste caso, a função $f(t)$ corresponde a um produto vetorial que pode ser escrito como

$$w_t = \sum_{i=1}^d a_{it} u_i \quad (2)$$

e conseqüentemente

$$f_t(x) = w_t(x): \forall t \in T; x \in R^d \quad (3)$$

onde $w_t(x)$ combina os coeficientes específicos a cada tarefa a e os coeficientes comuns u

ou em forma matricial

$$W = UA: W \in R^{d \times T} \quad (4)$$

A obtenção destes coeficientes é realizada a partir das observações históricas. Dentre outros métodos, o mais intuitivo (e comumente utilizado) é o que ajusta a função ao histórico disponível

$$\min\{\sum_{i=1}^m L \quad (5)$$

onde $L(\dots)$ é uma função que mede o erro empírico entre a saída do nosso modelo e os dados disponíveis.

5.0 - CASO ESTUDO

5.1 As distribuidoras em análise

A Aprendizagem colaborativa foi aplicada à projeção do consumo residencial para três empresas do Grupo Neoenergia: Coelba, Celpe e Cosern. A quarta distribuidora (Elektro) não foi contemplada porque, por suas características geográficas e sócio/econômicas, não havia certeza quanto à sua semelhança com as demais. Este aspecto encontra-se atualmente em análise e será reportado em breve.

A Figura 3 apresenta a evolução da carga da Coelba e ilustra nosso desafio. Não é evidente (ao menos para os autores deste trabalho) o motivo da rápida ascensão da carga a partir de finais de 2018; as temperaturas anormalmente altas do verão não seriam, por si, capazes de explicar tal dinâmica.

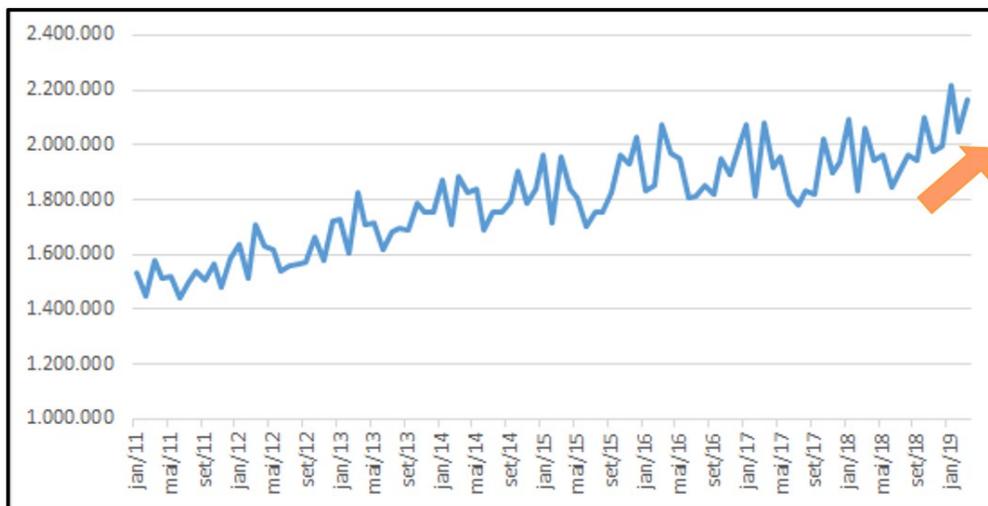


FIGURA 3 – Evolução da Carga da Coelba (MWmed)

O mesmo comportamento foi sentido na Celpe e na Cosern.

5.2 A ascensão inesperada da Carga

Detetado o comportamento anômalo dos últimos meses, seria intuitivo esperar que os modelos tradicionais experimentassem dificuldades em projetar a carga para o final de 2018/início de 2019. Seguindo um histórico de identificação desde 2011, a Figura 4 apresenta a projeção da carga (injetada) para o verão de 2019 seguindo o método tradicional: poderíamos observar um desvio mensal de até 6%. É possível perceber o crescimento anômalo, nunca experimentado no histórico e portanto de muito difícil projeção.

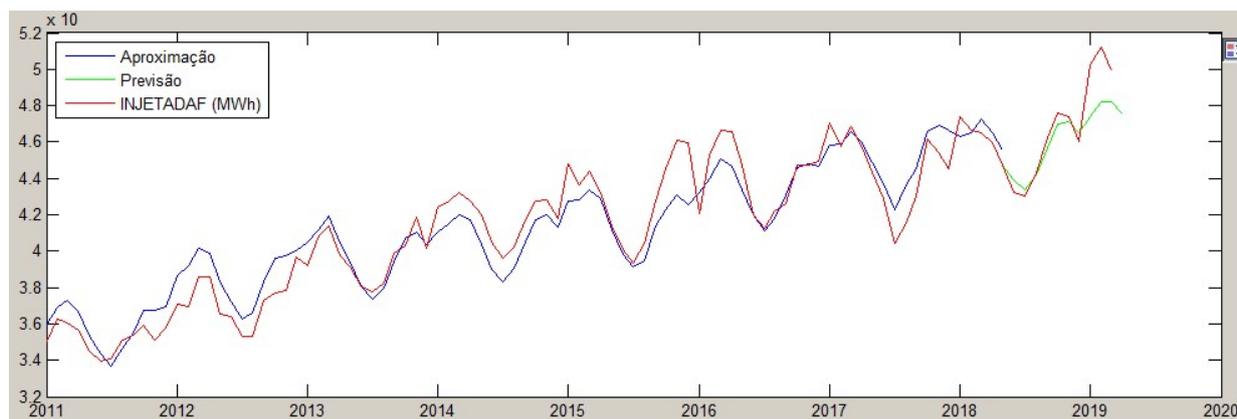


FIGURA 4 – Identificação / Projeção da Carga da COELBA

O mesmo se verifica para a Celpe, ilustrada na Figura 5

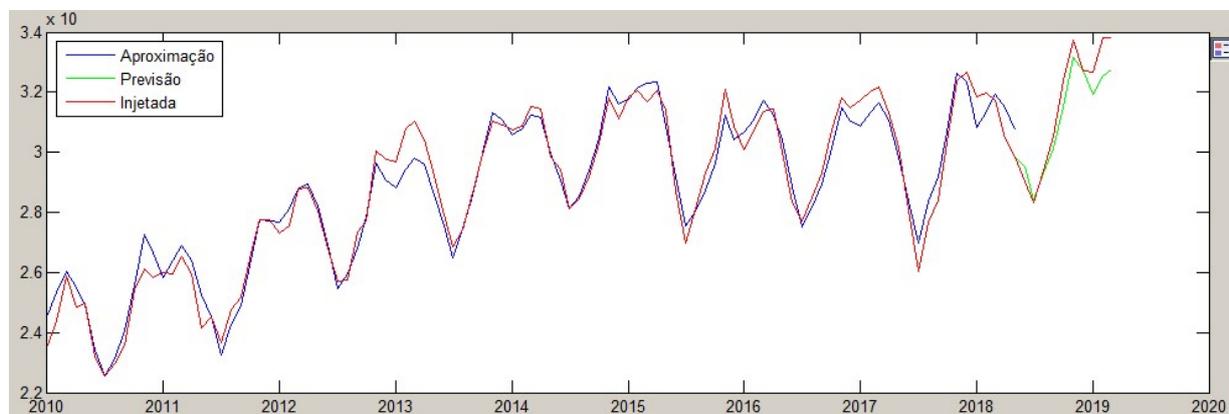


FIGURA 5 – Identificação / Projeção da Carga da CELPE

e para a Cosern, ilustrada na Figura 6

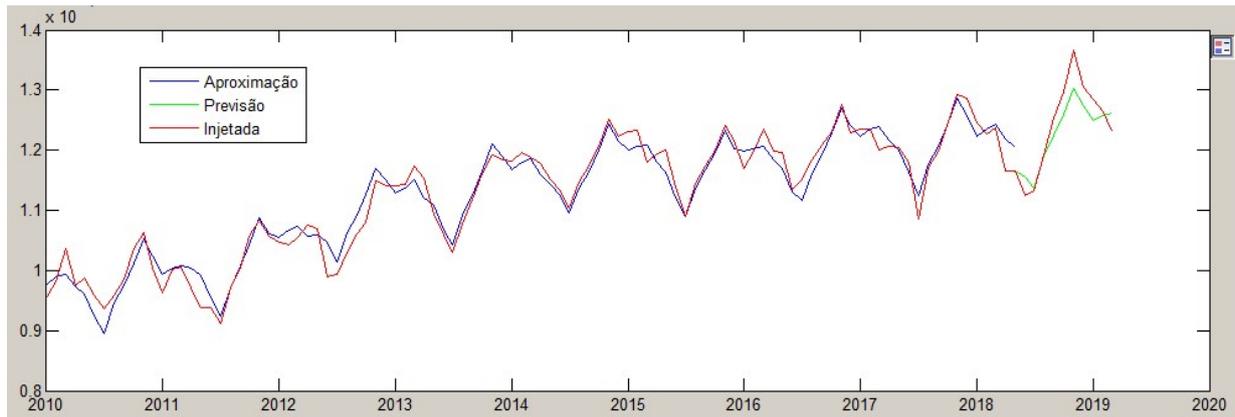


FIGURA 6 – Identificação / Projeção da Carga da COSERN

5.3 A aplicação da Aprendizagem Colaborativa

O comportamento anômalo foi detetado ao longo do ano de 2018. Seria muito difícil, senão impossível, usar apenas 12 a 18 meses para identificação/validação. Testamos então a técnica de aprendizagem colaborativa, usando para a identificação (ajuste) apenas o período de junho de 2017 a maio de 2018 (doze meses).

É interessante notar o poder multiplicativo do algoritmo colaborativo: o escasso histórico de apenas doze meses, aplicado às três distribuidoras, produz um banco de 36 meses de observações – ainda pequeno, mas já muito maior do que o anterior. Um número maior de distribuidoras (desde que com comportamento semelhante) poderia enriquecer ainda mais a informação disponível e contribuir para sua precisão.

A Figura 7 apresenta os desvios percentuais obtidos para as três distribuidoras. Nenhum supera o patamar de 2% - um ganho expressivo, considerando a escassez de dados e o ineditismo da dinâmica.

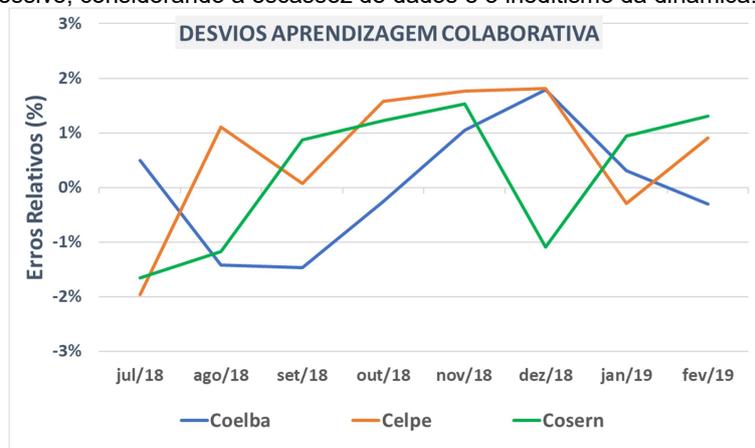


FIGURA 7 – Desvios percentuais para as três distribuidoras obtido com a Aprendizagem Colaborativa

Finalmente, o potencial da aprendizagem colaborativa é evidenciado pelas Figuras 8 a 10, que comparam os resultados obtidos para cada uma das distribuidoras com o uso de uma projeção individualizada (usando todo o histórico) através dos modelos já desenhados para a escassez de dados [4-6] e a aprendizagem colaborativa (considerando as informações apenas a partir de 2017). É possível observar a qualidade superior do modelo proposto.

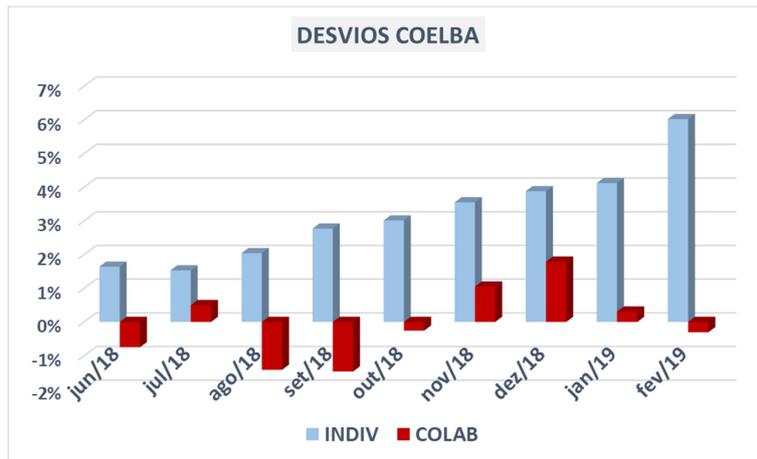


FIGURA 8 – Comparação desvios projeção individual x colaborativa – COELBA

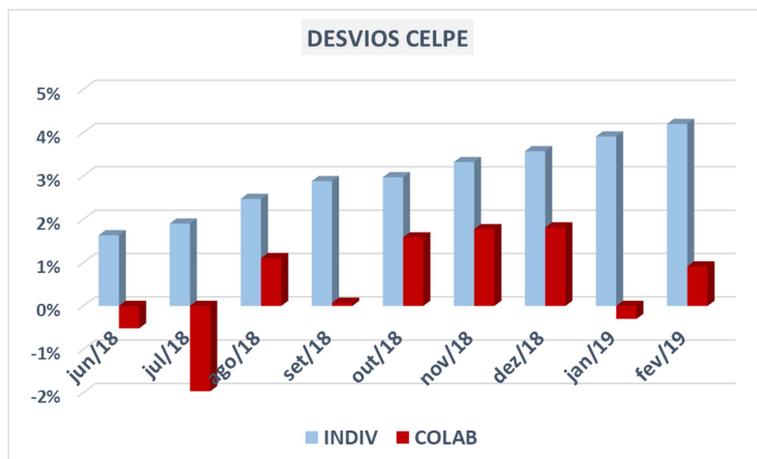


FIGURA 9 – Comparação desvios projeção individual x colaborativa – COELBA

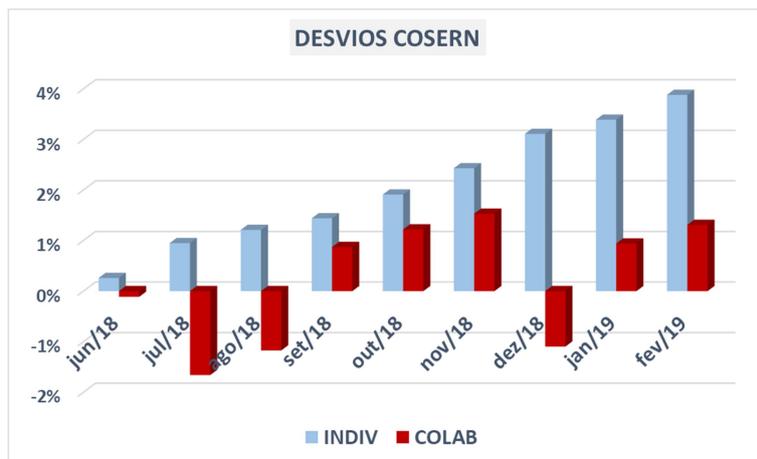


FIGURA 10 – Comparação desvios projeção individual x colaborativa – COELBA

6.0 - PESQUISAS FUTURAS

O trabalho aqui apresentado é apenas o primeiro passo na pesquisa sobre a aplicação da Aprendizagem colaborativa. Almejávamos apenas testar a potencialidade destas técnicas; o modelo inicial é ainda passível de aperfeiçoamentos, que devem ser introduzidos ao longo do tempo remanescente para a pesquisa. Neste momento, concentramos nossos esforços na projeção do consumo por classe e na análise da possibilidade de inclusão da distribuidora Elektro.

7.0 - AGRADECIMENTOS

Este trabalho é suportado pela linha de financiamentos para P&D ANEEL e faz parte da carteira de projetos da Elektro/Neoenergia.

8.0 - CONCLUSÕES

A projeção de carga/consumo das distribuidoras é insumo básico para inumeros estudos e informação fundamental para as estratégias da empresa. No entanto, é também um problema cada vez mais difícil. O comportamento do consumidor muda de forma cada vez mais veloz, e é fundamental que o tomador de decisão possa contar com ferramentas adequadas, capazes de inovar e adaptar-se à celeridade dos novos tempos.

O mundo é cada vez mais colaborativo, e nada mais natural que o desenvolvimento de modelos capazes de trocar experiências e aprendizados. É esta a nossa proposta ao oferecer uma ferramenta matemática feita sob medida para criar uma base de cooperação entre as empresas, com ganhos para todas.

A qualidade dos resultados até agora obtidos é encorajadora; acreditamos que este pode ser um primeiro passo para uma mudança de paradigma capaz de oferecer novos conceitos e vencer novos desafios.

9.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) R. Caruana, "Multitask Learning", Machine Learning, Volume 28, Issue 1, July 1997, pp 41-75
- (2) A. Argyriou, T. Evgeniou, and M. Pontil, "Multi-task feature learning," in Advances in Neural Information Processing Systems 19, pp. 41–48, 2006
- (3) Y. Zhang and Q. Yang, "A Survey on Multi-Task Learning", arxiv pre-print, 2017.
- (4) J. Szczupak, L. Pinto, L.H. Macedo, J. Pascon, R. Semolini, M. Inoue, C. Almeida ; F. R. Almeida, "Load Modeling and Forecast based on a Hilbert Space Decomposition", 2007 IEEE Power Engineering Society General Meeting, disponível na base de dados do repositório IEEEXPLORE <https://ieeexplore.ieee.org/document/4275991>
- (5) J. Szczupak, L.Pinto, L. H. Macêdo, D. Sica, J.Pascon, R. Semolini, M. Inoue, C. Almeida, F. R. Almeida, "Previsão inteligente de mercados de energia: mais que repetir o passado, antecipar o futuro", XIX Seminário Nacional de Produção e Transmissão de Energia Elétrica (SNPTEE), Outubro de 2007
- (6) L. Pinto, J. Szczupak, C. Almeida, L. Macedo, M. Inoue, R. Massaro, R. Semolini, J. Pascon, E. Albarelli, D. Tortelli, "Load Forecast under uncertainty: Accounting for the economic crisis impact", PowerTech 2009 IEEE Bucharest, pp. 1-5, 2009.

10.0 - DADOS BIOGRÁFICOS

	<p>Leontina Pinto - Engenheira Elétrica, M.Sc. Engenharia de Sistemas (otimização) e D.Sc. em Matemática, todos pela UFRJ. Foi pesquisadora no Cepel, Professora na COPPE/UFRJ e na PUC-RIO. É diretora executiva da ENGENHO desde 1988, onde desenvolve soluções para o setor de energia elétrica nacional e internacional.</p>
	<p>Jacques Szczupak – Engenheiro Elétrico, M.Sc. em Engenharia Eletrônica, ambos pela UFRJ e Ph.D. em Engenharia Elétrica pela Universidade da Califórnia. Foi pesquisador no Cepel, Professor na COPPE/UFRJ e na PUC-RIO. É diretor técnico-administrativo na ENGENHO desde 1988, onde desenvolve soluções para o setor de energia elétrica nacional e internacional.</p>
	<p>Robinson Semolini - Graduado em Estatística (Unicamp), Mestrado em Engenharia Elétrica e de Computação (Unicamp) com especialização em Machine Learning (Redes Neurais e Support Vector Machine), Doutorado em Economia (Unicamp) com especialização em análise de eficiência aplicada ao setor de Distribuição de Energia Elétrica. Possui 25 anos de experiência em Modelagem Estatística, Econometria e Otimização Matemática aplicadas ao Mercado Financeiro e Setor Elétrico. Atualmente atua como Especialista Sênior pelo Grupo NEOENERGIA.</p>