

Descoberta da topologia do sistema na ausência de sinais com redes neurais autoassociativas

Jakov Krstulovic, Vladimiro Miranda, Hrvoje Keko e Jorge Pereira

Resumo – Este artigo apresenta uma nova solução para a estimação do estado de aberto ou fechado de interruptores numa rede de transmissão ou distribuição, quando a informação está ausente do SCADA por falha ou erro de transmissão. A solução é estimada recorrendo-se a redes neurais autoassociativas. A demonstração é feita comparando o comportamento de uma rede global com uma rede local, demonstrando-se que é suficiente informação local para se obterem resultados corretos, mesmo na ausência de um número importante de sinais no SCADA em subestações com topologia complexa.

Palavras chave – Estimação de estado, Redes autoassociativas, medidas falhadas.

I. INTRODUÇÃO

PARA que num EMS (Energy Management System) ou DMS (Distribution Management System) se possa executar o cálculo de fluxo de potência e as demais funções, é necessário habitualmente rodar uma Estimação de Estado e, previamente a esta, definir ou estimar a topologia da rede. Isto significa definir qual o estado de aberto ou fechado dos interruptores que determinam as linhas em serviço e as malhas que se podem ou não formar. Em particular, importa rodar um configurador que defina a estrutura de ligação das barras em cada subestação. Porém, podem ocorrer falhas ou erros de transmissão dos sinais entre sensores vigiados por unidades remotas e o SCADA no centro de controle, impossibilitando essa determinação.

Neste caso, é usual recorrer-se a regras heurísticas para "adivinhar" o estado dos interruptores. Essas regras, nalguns casos, podem ser bem triviais: por exemplo, algumas regras observam correntes em linhas para deduzir se o aparelho está aberto ou não. Mas noutros casos podem não ser aplicáveis, como em estruturas complexas de subestações.

Neste trabalho apresenta-se uma abordagem diferente da habitual, baseada em redes neurais autoassociativas. Estas redes, com número de entradas igual ao número de saídas, têm a propriedade de, após convenientemente treinadas, a aplicação de um padrão coerente com o conjunto aprendido provocar na saída um padrão igual com erro diminuto. Esta propriedade tem sido aproveitada para a reconstrução de sinais falhados ou ausentes em redes de sensores, como será descrito nos parágrafos seguintes.

Neste trabalho, será aplicado este conceito à reconstrução

de sinais ausentes do estado de interruptores. Aliás, também se pode aplicar o mesmo princípio a sinais suspeitos de erro, bastando assumir que o sinal correto está ausente do conjunto de medidas adquiridas pelo SCADA.

Será demonstrado num exemplo que a informação sobre a topologia de uma rede elétrica está embebida nos sinais elétricos de potência e tensão da rede e que uma rede autoassociativa pode ser treinada para descobrir essa informação, na ausência de informação direta sobre o estado dos interruptores. E será mostrado que essa informação está residente em variáveis locais, não sendo, portanto necessário treinar uma rede neural de tamanho excessivo. Esta propriedade permite imaginar um mosaico de redes neurais apenas baseada em informação local, ajudando num SCADA a reconstituir a topologia da uma rede e sendo um instrumento coadjuvante importante do papel de um Estimador de Estado.

II. PSEUDOMEDIDAS E TOPOLOGIA

A forma tradicional de resolver o problema de medidas ausentes, num Estimador de Estado, é a adição de pseudomedidas, normalmente construídas a partir de informação histórica do sistema. Quando as medidas em falta são respeitantes ao estado de aberto ou fechado de interruptores, como se disse, é tradicional aplicarem-se regras simples (por exemplo, se uma linha apresenta fluxo nulo, um interruptor deve estar aberto) ou confiar na última informação anterior disponível.

A estimativa da topologia é uma preocupação antiga. Já em [1] se pode encontrar um modelo para identificar informação errada relativamente à topologia. Em alternativa, outros autores propuseram teste de hipóteses [2] ou propuseram a divisão do conjunto de dados em conjuntos de "certos" e "suspeitos" e, partindo de um modelo Bayesiano, atribuíram probabilidades condicionais *a posteriori* às possíveis combinações de estados dos interruptores suspeitos [3].

Mais recentemente, [4] apareceu um modelo baseado ainda numa abordagem clássica de mínimos quadrados tentando descobrir o estado dos interruptores que minimize o quadrado dos erros das medidas, com linearização das equações descrevendo o fluxo de potência através dos aparelhos.

Estes são apenas exemplos e não uma análise exaustiva dos esforços de modelização para a descoberta do estado desconhecido de interruptores. Porém, vê-se que o problema parece ainda não ter tido uma solução satisfatória. Além disso, com o progresso dos centros de controle na distribuição, onde as variáveis topológicas passam a poder ser dominantes, mais importa integrar, no procedimento de estimação de estado, a descoberta da topologia de rede subjacente.

V. Miranda (vmiranda@inescporto.pt), J.Krstulovic (jopara@inescporto.pt), H. Keko (hkeko@inescporto.pt) estão com o INESC TEC (INESC Tecnologia e Ciência, coordenado pelo INESC Porto), Portugal.

V. Miranda e H. Keko estão também com a FEUP, Faculdade de Engenharia da Universidade do Porto, Portugal. J. Pereira está também com a FEP, Faculdade de Economia da Universidade do Porto, Portugal.

III. REDES NEURAIS AUTOASSOCIATIVAS

Uma rede neural é autoassociativa se for treinada para oferecer, à saída, um vetor igual ao que lhe é apresentado à entrada. Obviamente, isso implica que o número de neurónios da camada de entrada é igual ao da saída.

A arquitetura mais comum é a de uma rede com apenas uma camada escondida, com essa camada de menor dimensão que a entrada e saída, embora haja casos em que a camada intermédia possa ser de dimensão superior [5][6]. Esta última opção ocorre quando a dimensão dos vetores a apresentar à rede é pequena e não se torna viável uma rede autoassociativa com uma camada intermédia ainda menor e praticamente trivial. Por outro lado, sendo certo que as redes autoassociativas foram propostas inicialmente para compressão de imagem e de dados (tomando como codificação comprimida o vetor de sinais à saída da camada intermédia), torna-se lógica uma arquitetura com estrangulamento intermédio [7][8][9].

A Fig. 1 ilustra o conceito de rede autoassociativa de camada escondida única. Podem-se conceber redes de múltiplas camadas mas o seu treinamento direto torna-se difícil [10].




Fig. 1. Representação esquemática de uma rede neural autoassociativa, com estrangulamento na camada intermédia ou escondida. A rede executa a projeção f dos dados de um espaço S num espaço S' e projeta de volta em S com f^{-1} os mesmos dados.

Adequadamente treinada, uma rede autoassociativa aprende o padrão correspondendo ao conjunto de dados e armazena nos seus pesos essa informação sobre o *manifold* onde os dados se encontram. Quando lhe é apresentado um vetor desconhecido, pertencendo ao padrão de dados original, a projeção e reprojeção devolve o mesmo vetor (com erro mínimo). Porém, se o vetor apresentado não estiver consonante com o padrão dos dados usados na aprendizagem, a rede não executa corretamente a projeção/reprojeção e o vetor na saída apresenta um erro apreciável relativamente ao da entrada.

Esta propriedade pode ser aproveitada para recompor dados corrompidos – por exemplo, se ao vetor de entrada faltar informação sobre alguma componente. Nesse caso, é possível procurar qual o valor da entrada em falta que minimizaria o erro entre o vetor de entrada e o de saída, ou seja, procurar o ponto sobre o *manifold* aprendido pela rede cujas coordenadas são compatíveis com a parte do vetor que é conhecida. A aplicação óbvia é na reconstrução ou recomposição de sinais falhados ou ausentes em redes de sensores [11] [12] [13].

Foram propostos vários modelos de otimização para tal. O modelo reportado como mais produtivo é aquele que

efetivamente busca um valor para os sinais ausentes minimizando uma função do erro ou "distância" entre o vetor de entrada e saída, e não apenas entre a entrada e saída correspondente dos sinais ausentes. Por exemplo, em [14] foi adotado um Algoritmo Genético e em [15] um EPSO (Enxame Evolucionário de Partículas) [16][17][18].

O problema da recuperação de sinais ausentes reais fica representado por

$$\begin{aligned} \min_{x_s} \quad & \varphi = D(\boldsymbol{\varepsilon}(x_s)) \\ \text{su}j.: \quad & \boldsymbol{\varepsilon} = \mathbf{x} - \mathbf{x}' \\ & \mathbf{x}' = \mathbf{M}(\mathbf{x}) \\ & \mathbf{x}, \mathbf{x}' \in \Re \quad \text{e} \quad x_s \subset \mathbf{x} \end{aligned} \quad (1)$$

em que

$\mathbf{x}, \mathbf{x}'$ – vetor de entrada e de saída

x_s – componentes desconhecidas do vetor $\mathbf{x}$

$\boldsymbol{\varepsilon}$ – erro entre $\mathbf{x}$ e $\mathbf{x}'$

$D(\cdot)$ – distância entre $\mathbf{x}$ e $\mathbf{x}'$ medida numa métrica adequada

$\mathbf{M}$ – atuação da rede autoassociativa

Note-se que esta representação é propositadamente genérica na definição da distância D . A assunção de uma distância Euclidiana levaria ao conhecido critério dos mínimos quadrados ou mínimo erro quadrático. Nada obriga, porém, a que esse seja o critério apropriado para o problema em causa.

A aplicação de redes neurais autoassociativas em problemas de sistemas de potência não tem sido comum, podendo citar-se os trabalhos [19] e [20] como exemplos raros.

IV. PREPARAÇÃO DOS TESTES

A. Criação de uma base de dados

Como sistema de teste, foi escolhido o sistema IEEE RTS de 24 barras [21]. Criaram-se então cenários de operação da seguinte forma:

- Definiu-se uma curva de carga a partir da informação em [20] e sortearam-se valores de carga entre o mínimo e o máximo.
- A cada nó foi atribuída uma carga proporcional de acordo com a repartição de carga original.
- Simulou-se uma variação de carga adicionando perturbações Gaussianas com $\sigma = 5\%$.

A preparação de cenários de geração foi efetuada assim:

- Definiu-se uma localização para interruptores na rede (ver a Secção V).
- A escolha de uma topologia (interruptores abertos e fechados) foi efetuada por sorteio.
- Para cada cenário agrupando uma topologia e um nível de carga foi corrido um Fluxo de Potência Ótimo (FPO) AC e fixado o cenário de geração resultante.

Com este processo, acumularam-se 20000 cenários.

A cada cenário, foi associado um pretensão conjunto de medidas, como se recolhidas num SCADA:

- Cada medida de natureza elétrica tomou como base o valor do FPO no cenário.
- A cada medida elétrica adicionou-se ruído Gaussiano

com $3\sigma = 1\%$ da maior grandeza medida (em p.u.), simulando erros de medida, transmissão e não simultaneidade – um valor apreciável, se tivermos em conta apenas a possível classe de precisão dos aparelhos de medida, mas que não originou erros grosseiros.

Para o treino de redes autoassociativas:

- A partir da base de dados, definiram-se conjuntos de aprendizagem e validação
- Definiu-se a arquitetura da rede neural autoassociativa, com camada intermédia única e com funções de ativação na seguinte forma: camada de entrada linear e restantes camadas com funções do tipo $2\arctan()/\pi$.
- O critério ϕ usado no treino foi o Erro Mínimo Absoluto (MAE).

B. Forçando um resultado binário

No sistema de equações (1), as variáveis x_s são tomadas como reais e contínuas, mas no problema de identificação topológica as variáveis (estados dos interruptores) são binárias, definindo-se o estado fechado pelo valor -1 e o aberto por 1. Para conduzir a um resultado inteiro, a função objetivo do problema é modificada para

$$\min_{x_s} \psi = \phi + k \sum_{s=1}^S (1 - x_s^2) \quad (2)$$

$\text{su}j.: k \in \mathbb{R}^+$

onde

S – número de interruptores

x_s – sinal correspondendo ao interruptor s

k – fator de penalidade

O parâmetro k tem por efeito conduzir os valores x_s a -1 ou 1 (soluções da equação quadrática) quando ψ é minimizado, evitando soluções ambíguas no intervalo $\langle -1, 1 \rangle$.




Fig. 2. Rede IEEE 24 RTS com 5 interruptores adicionados.

V. VALIDADE DE UM MODELO GLOBAL

A. Interruptores disseminados na rede

Esta secção apresenta o resultado para a modelização dos estados de interruptores efetuada por uma única rede autoassociativa trabalhando com todas as medidas disponíveis no SCADA.

Tomando a rede representada na Fig. 2 (com 5 interruptores dispersos na rede), preparou-se uma rede autoassociativa com 121 entradas e saídas (tomando 116 medidas e 5 informações sobre interruptores) e uma camada intermédia de 60 neurónios, treinada com 3000 cenários. O tempo de treino foi de cerca de 10 minutos num PC corrente.

De seguida, sortearam-se cargas e sinais ausentes, organizando 5 conjuntos de 10000 cenários, cada um com um número fixo de interruptores (de 1 a 5) com informação ausente. Ao vetor de resposta da rede autoassociativa foi aplicado um algoritmo EPSO resolvendo o problema (2) a partir de uma inicialização aleatória em $[-1, 1]$, com 30 partículas e progredindo durante 40 gerações.

A Tabela 1 resume de forma estatística o resultado. Cada linha corresponde à simulação sobre 1000 cenários na ausência de informação sobre o estado de um número fixo de interruptores num total de 5. Note-se que há uma diferença conceptual entre sinais reconstruídos e topologias reconstruídas: deteta-se no caso de 3 sinais falhados, porque num dos cenários houve duas reconstruções erradas mas conta apenas como uma topologia falhada.

A eficiência da rede autoassociativa fica demonstrada. A eficiência na recuperação de topologias foi acima de 99,9% para 1 ou 2 sinais falhados, e ainda acima de 99,71% para 5 sinais simultaneamente ausentes (ou seja, ignorância total). Como é normal esperar, a eficiência diminui ligeiramente quando o número de interruptores com informação em falta aumenta. Também é interessante observar que a proporção de estados de interruptores erradamente reconstruídos se mantém extremamente constante e próximo de 0,55%, o que é um valor extremamente baixo.

TABELA 1 – RESULTADOS SOBRE 50000 CENÁRIOS PARA RECOMPOR SINAIS AUSENTES SOBRE O ESTADO DE 5 INTERRUPTORES

Sinais ausentes	Sinais reconstruídos			Topologias reconstruídas	
	Corretos	Errados		Erradas	Corretas
1	9980	8	0,080%	8	99,92%
2	19990	10	0,050%	10	99,90%
3	29983	17	0,057%	16	99,84%
4	39984	16	0,040%	16	99,84%
5	49971	29	0,058%	29	99,71%
Total	149920	80	0,053%	79	99,84%

Para confirmar estes resultados, preparou-se um novo caso desta vez com 10 interruptores, cuja localização está na Fig. 3., e uma rede 126-60-126. Os resultados (Tabela 2) mostram que o aumento da dimensão do problema e do número de dados desconhecidos compromete progressivamente a qualidade de recuperação de medidas ausentes pela rede autoassociativa global, dada a dificuldade do treinamento.




Fig. 3 – Rede IEEE 24 RTS com 10 interruptores adicionados.

TABELA 2 – RESULTADOS SOBRE 50000 CENÁRIOS PARA RECOMPOR SINAIS AUSENTES SOBRE O ESTADO DE 10 INTERRUPTORES

Sinais ausentes	Topologias reconstruídas c/penalidade		
	Erradas	Corretas	% Corretas
1	22	978	97.80%
2	51	949	94.90%
3	60	940	94.00%
4	93	907	90.70%
5	103	897	89.70%
6	121	879	87.90%
7	132	868	86.80%
8	176	824	82.40%
9	179	821	82.10%
10	196	804	80.40%
Total	1133	8867	88.67%

B. Estruturas complexas em subestações

Uma estrutura tradicionalmente considerada difícil de identificar respeita ao esquema de ligações em serviço numa subestação pois as ligações entre interruptores têm impedância desprezável (nula para efeitos práticos) e, portanto, não é possível aplicar-se um modelo de fluxo de potência ortodoxo.

Para teste foi usada uma configuração de barramentos representada esquematicamente na Fig. 3, correspondendo ao nó 15 do sistema IEEE RTS e adaptada de [22]. Nos testes a seguir descritos não foi considerado o caso de desligamento completo do gerador ou de uma linha, pois o efeito seria semelhante ao já estudado anteriormente. Foram apenas considerados esquemas de conexão das linhas e gerador a um ou outro dos barramentos e ainda a hipótese de os barramentos estarem conjugados.

Neste teste, existem 7 disjuntores cujo estado pode ser desconhecido. Uma rede autoassociativa de 125-60-125 neurónios foi treinada (em cerca de 14 minutos) de modo análogo ao descrito anteriormente e os testes admitiram desconhecimento de 1 até à totalidade dos 7 disjuntores.




Fig. 4. Esquema de ligações na subestação 15 com 7 disjuntores

A Tabela 2 apresenta os resultados estatísticos em mil cenários para cada caso de sinais ausentes. A precisão conseguida é muito impressionante, mesmo no caso da ausência total de informação (desconhecimento do estado dos 7 aparelhos) onde mesmo assim conseguiu um acerto de mais de 80% das vezes.

Estes testes ilustram que uma rede autoassociativa pode ser treinada de modo a reconstruir a topologia de uma rede mesmo na ausência de informação substancial sobre o estado dos seus interruptores (ou disjuntores).




Fig. 5. Área abrangida pelas medidas usadas pela rede autoassociativa local associada ao nó 15

TABELA 2 – RECONSTRUÇÃO EM 1000 CENÁRIOS DA TOPOLOGIA INTERNA DO NÓ 15

Sinais ausentes	Sinais reconstruídos		Topologias reconstruídas	
	Corretos	Errados	Erradas	Corretas
1	1000	0	0	100,00%
2	1999	1	1	99,90%
3	2997	3	2	99,80%
4	3993	7	4	99,60%
5	4973	27	9	99,10%
6	5756	244	56	94,40%
7	5999	1001	182	81,80%
Total	26717	1283	254	96,37%

VI. VALIDADE DE UM MODELO LOCAL

Se a hipótese de trabalho é que a informação sobre a topologia de uma rede elétrica está embecida nos valores elétricos, é plausível assumir-se que a informação sobre o estado de um interruptor em particular esteja fundamentalmente disseminada em variáveis topologicamente vizinhas. A ser assim, as redes autoassociativas a usar seriam de muito menor dimensão, com enormes vantagens.

Para testar essa conjectura, e tomando o problema anterior relativamente ao nó 15, definiu-se uma rede autoassociativa com apenas 31-25-31 neurónios, abrangendo medidas apenas da zona marcada na Fig. 5. Neste caso, o tempo de treinamento foi apenas de cerca de 1 minuto.

Os resultados para 7000 cenários, inscritos na Tabela 3, mostram que o desempenho da rede autoassociativa local, para falhas de sinal até 4 disjuntores, tem um desempenho equivalente ao conseguido com uma rede global. A degradação da qualidade do resultado quando falham sinais de 6 e 7 disjuntores não deve surpreender, tendo em conta que este número já constitui uma fração importante (cerca de 20%) das entradas na rede autoassociativa.

Este resultado é importante porque mostra que com uma rede muito simples, de treino muito expedito e com base apenas em informação local, é possível obter resultados muito apreciáveis, em especial se for possível definir um modo ótimo de escolher as medidas que melhor descrevem a topologia interior do nó.

TABELA 3 – RECONSTRUÇÃO DA TOPOLOGIA INTERNA DO NÓ 15 COM UMA REDE AUTOASSOCIATIVA BASEADA EM MEDIDAS LOCAIS

Sinais ausentes	Sinais reconstruídos		Topologias reconstruídas	
	Corretos	Errados	Erradas	Corretas
1	1000	0	0,00%	100,00%
2	1998	2	0,10%	99,90%
3	2993	7	0,23%	99,60%
4	3983	17	0,43%	99,30%
5	4833	167	3,46%	93,70%
6	5449	551	10,11%	82,80%
7	5692	1308	22,98%	67,90%
Total	25948	2052	7,91%	91,89%

VII. MOSAICO DE REDES LOCAIS

O último exemplo recorre ao conceito de mosaico de redes locais para a reconstrução de informação ausente. A Fig. 6 representa 5 redes autoassociativas coletando informações locais e dedicadas cada uma à reconstituição da informação sobre um interruptor. As redes têm as dimensões seguintes:

Rede do sw1	15-10-15
Rede do sw2	19-14-19
Rede do sw3	17-12-17
Rede do sw4	17-12-17
Rede do sw5	13-08-13

Seguida a mesma metodologia de treino anteriormente descrita e o mesmo processo de teste, obtiveram-se os resultados estatísticos apresentados na Tabela 4. Estes muito bons resultados ocorrem porque cada rede autoassociativa faz uma análise independente. As redes são de muito menor dimensão e, portanto, parece ser possível treiná-las melhor.




Fig. 6 – Mosaico de redes autoassociativas locais visando cada uma a reconstrução da informação sobre um interruptor.

TABELA 4 – RESULTADOS PARA RECOMPOR SINAIS AUSENTES SOBRE O ESTADO DE 5 INTERRUPTORES COM REDES LOCAIS

Sinais ausentes	Sinais reconstruídos			Topologias reconstruídas	
	Corretos	Errados		Erradas	Corretas
1	1000	0	0,00%	0	100,00%
2	2000	0	0,00%	0	100,00%
3	2998	2	0,067%	2	99,80%
4	3998	2	0,05%	2	99,80%
5	4999	1	0,02%	1	99,90%
Total	14995	5	0,03%	5	99,90%

VIII. CONCLUSÕES

Este artigo aborda de modo não convencional o problema da reconstrução topológica de redes elétricas, em processos de estimação de estado. A hipótese de trabalho era de que a informação sobre a topologia de uma rede se encontra embecida (distribuída) nos valores das medidas elétricas do sistema – e de que seria possível treinar redes neurais autoassociativas para aprender a reconhecer essa topologia, extraindo a informação dessas medidas elétricas.

Duas conclusões importantes se avolumam:

1. O uso de redes autoassociativas para recompôr sinais ausentes sobre o estado de interruptores é viável e eficiente.
2. Uma solução de mosaico de redes autoassociativas funciona aparentemente ainda melhor do que uma única rede global.

A viabilidade do uso do conceito proposto foi mesmo posta à prova num caso especialmente difícil, que é o da topologia em barramentos de subestações, com indicações muito positivas. Não sendo possível alcançar um êxito de 100% (pois há casos de indecidibilidade), mostrou-se como uma rede

autoassociativa pode recompor uma topologia complexa mesmo na ausência de substancial parte da informação.

Esta ferramenta tem enorme potencial para ser complementar dos processos de estimação de estado clássicos. Além disso, permite imaginar que possa ser uma solução para as redes de distribuição onde as variáveis topológicas podem ser, de certo modo, dominantes. Finalmente, o princípio da estimação local poderá ser útil como coadjuvante para estimação em microrredes num controlador centralizado, dentro do paradigma de *smart grids*, nomeadamente quando a estimação por modelo global se revele inviável.

NOTA

Este trabalho integra-se parcialmente nos projetos LASCA PTDC/EEA-EEL/104278/2008 e GEMS PTDC/EEA-EEL/105261/2008, financiados pela FCT, Portugal.

REFERENCES

- [1] F.F. Wu and W.-H.E. Liu, "Detection of topology errors by state estimation", *IEEE Transactions on Power Systems*, Vol. 4, no. 1, pp. 176-183, Feb 1989.
- [2] A.S. Costa and M.C. dos Santos, "Real-Time Monitoring of Distributed Generation Based on State Estimation and Hypothesis Testing", *Proc. of IEEE Lausanne Power Tech 2007*, pp. 538-543, Jul 2007.
- [3] E.M. Lourenco, A.S. Costa and K.A. Clements, "Bayesian-based hypothesis testing for topology error identification in generalized state estimation", *IEEE Transactions on Power Systems*, Vol. 19, no. 2, pp. 1206-1215, May 2004.
- [4] E. Caro, A. J. Conejo, and A. Abur, "Breaker status identification", *IEEE Trans. Power Syst.*, vol. 25, no. 2, pp. 694-702, May 2010.
- [5] A. R. G. Castro, V. Miranda and S. Lima, "Transformer fault diagnosis based on autoassociative neural networks", *Proceedings of ISAP 2011-Conference on Intelligent Systems Applications to Power Systems*, Crete, Greece, Oct 2011.
- [6] V. Miranda, A. R. G. Castro and S. Lima, "Diagnosing faults in power transformers with autoassociative neural networks and mean shift", *IEEE Transactions on Power Delivery* (accepted for publication), 2012
- [7] G.W. Cottrell, P. Munro and D. Zipser, "Learning internal representations from gray-scale images: An example of extensional programming", *Proceedings of the Ninth Annual Conference of the Cognitive Science Society*, Seattle (WA), USA, 1987
- [8] M.K. Fleming, G.W. Cottrell, "Categorization of faces using unsupervised feature extraction", *Proceedings of IJCNN - International Joint Conference on Neural Networks*, vol. 2, pp. 65-70, San Diego (CA), USA, 17-21 Jun 1990
- [9] B. Golomb and T. Sejnowski, "Sex Recognition from Faces Using Neural Networks", in A. Murray (ed.), in *Applications of Neural Networks*, pp. 71-92, Kluwer Academic Publishers, 1995
- [10] G. E. Hinton and R. R. Salakhutdinov, "Reducing the Dimensionality of Data with Neural Networks", *Science*, Vol. 313, no. 5786, pp. 504 - 507, July 2006
- [11] Narayanan, S., R.J. Marks II, I. L. Vian, I. Choi, M.A. El-Sharkawi & B. B. Thompson, "Set Constraint Discovery: Missing Sensor Data Restoration Using Auto-Associative Regression Machines", *Proceedings of the 2002 International Joint Conference on Neural Networks*, 2002 IEEE World Congress on Computational Intelligence, pp. 2872-2877, Honolulu (Hawaii), USA, May12-17, 2002.
- [12] B. B. Thompson, R.J. Marks and M.A. El-Sharkawi, "On the Contractive Nature of Autoencoders: Application to Missing Sensor Restoration", *Proceedings of the International Joint Conference on Neural Networks*, Vol. 4, pp. 3011-3016, July 2003
- [13] Narayanan, S., R.J. Marks II, I. L. Vian, I. Choi, M.A. El-Sharkawi & B. B. Thompson, "Set Constraint Discovery: Missing Sensor Data Restoration Using Auto-Associative Regression Machines", *Proceedings of the International Joint Conference on Neural Networks*, IEEE World Congress on Computational Intelligence, Honolulu (Hawaii), USA, May12-17, 2002.
- [14] Abdella, M. and Marwala, T., "The use of genetic algorithms and neural networks to approximate missing data in databases", *Comput. Inf.*, no. 24, pp 577-589, 2005
- [15] V. Miranda, J. Krstulovic, H. Keko, C. Moreira and J. Pereira, "Reconstructing missing data in State Estimation with autoencoders", *IEEE Transactions on Power Systems* (accepted for publication), 2012
- [16] V. Miranda and N. Fonseca, "EPSO - Best-of-two-worlds metaheuristic applied to power system problems", *Proceedings of WCCI 2002 - World Congress on Computational Intelligence - CEC - Conference on Evolutionary Computing*, Honolulu, Hawaii, USA, May 2002.
- [17] V. Miranda, H. Keko and A. Jaramillo, "EPSO: Evolutionary Particle Swarms", Ch. 6 in *Advances in Evolutionary Computing for System Design*, L. Jain et al. Eds., Springer, series: Studies In Computational Intelligence, ISBN 978-3-540-72376-9, Volume 66, pp. 139-168, 2007.
- [18] Vladimiro Miranda, Hrvoje Keko and Álvaro Jaramillo Duque, "Stochastic Star Communication Topology in Evolutionary Particle Swarms (EPSO)", *International Journal of Computational Intelligence Research*, vol. 4, no.2, 2008
- [19] Wei Qiao, Zhi Gao, Ronald G. Harley, Ganesh K. Venayagamoorthy, "Robust neuro-identification of nonlinear plants in electric power systems with missing sensor measurements", *Engineering Applications of Artificial Intelligence*, no. 21, pp. 604-618, 2008
- [20] Salman Mohagheghi, Ganesh K. Venayagamoorthy and Ronald G. Harley, "Optimal Wide Area Controller and State Predictor for a Power System", *IEEE Tr. PWRS*, vol. 22, no. 2, pp. 693-705, May 2007
- [21] IEEE RTS Task Force of APM Subcommittee, "IEEE Reliability Test System", *IEEE PAS*, Vol-98, No. 6, pp 2047-2054, Nov/Dec. 1979.
- [22] R. Billinton, P. K.Vohra, and S. Kumar, "Effect of station originated outages in a composite system adequacy evaluation of the IEEE reliability test system," *IEEE Power App. Syst.*, vol. PAS-104, pp. 2249-2656, Oct. 1985

Jakov Krstulovic graduou-se pela Faculdade de Engenharia Elétrica e Computação da Universidade de Zagreb, Croácia, em 2008. É presentemente aluno de Doutorado da Faculdade de Engenharia Elétrica, Mecânica e Arquitetura Naval da Universidade de Split, Croácia, e também da Faculdade de Engenharia da Universidade do Porto, Portugal. Desde Outubro de 2010 é pesquisador na Unidade de Sistemas de Energia do INESC TEC, Portugal. Os seus interesses são a estimação de estado e a integração de energia eólica em grande escala

Vladimiro Miranda recebeu os graus de Licenciado e Doutoramento em Engenharia Eletrotécnica pela Faculdade de Engenharia da Universidade do Porto (FEUP), Portugal, em 1977 e 1982. Em 1981 ingressou na FEUP e tem presentemente a posição de Professor Catedrático. Também é pesquisador do INESC desde 1985 e ocupa presentemente o cargo de Diretor do INESC Porto, entidade coordenadora do INESC TEC - INESC Tecnologia e Ciência, uma organização avançada de pesquisa em Portugal. Foi autor de muitos artigos e responsável por muitos projetos internacionais em áreas relacionadas com a aplicação de Inteligência Computacional aos Sistemas de Potência. É Fellow do IEEE.

Hrvoje Keko graduou-se pela Faculdade de Engenharia Elétrica e Computação da Universidade de Zagreb, Croácia. É presentemente aluno de Doutorado da Faculdade de Engenharia da Universidade do Porto, Portugal, do Programa Doutoral em Sistemas Sustentáveis de Energia. É também desde 2008 pesquisador na Unidade de Sistemas de Energia do INESC TEC, Portugal. Os seus interesses incluem inteligência computacional, previsão de potência eólica e impacto da mobilidade elétrica no planeamento e operação de sistemas elétricos.

Jorge Pereira recebeu o grau de Licenciado em Matemática Aplicada pela Faculdade de Ciências da Universidade do Porto, Portugal. Em 1995 e 2002 completou os graus de Mestre e Doutor pela FEUP. Em 1991 ingressou no INESC ocupa presentemente a posição de Investigador Sênior no INESC TEC. Desde 1995 é Professor Auxiliar na Faculdade de Economia da Universidade do Porto. Foi responsável por diversos projetos associados ao desenvolvimento de sistemas de DMS e aplicação de *soft computing* a Sistemas de Potência, nomeadamente ao problema da estimação de estado.