

Um Reconhecedor de Padrões Espaço-Temporais Inspirado no Neocórtex

Rafael Coimbra Pinto

Universidade Federal do Rio Grande do Sul - 2009/1

Orientador: Prof. Paulo Martins Engel

Roteiro

Introdução

Trabalhos Relacionados

Memory-Prediction Framework (MPF)

Hierarchical Temporal Memory (HTM)

Self-Organizing Map (SOM)

Recurrent Self-Organizing Map (RSOM)

Par SOM-RSOM

Hierarchical Quilted Self-Organizing Map (HQSOM)

LoopSOM

HQSOM+

Conclusões

Referências

Introdução

Há a hipótese de que o nosso neocórtex é um reconhecedor/classificador hierárquico de padrões espaço-temporais

Sabe-se que ele é composto por várias camadas similares

Supõe-se que cada camada corresponde a um diferente grau de abstração

Analisa características de baixo nível na primeira camada (ex.: a primeira camada cortical visual, a V1, analisa pequenas linhas)...

...E características de alto nível nas camadas mais altas, como conceitos abstratos

Trabalhos Relacionados

Memory-Prediction Framework (Hawkins 2005)

Propõe uma arquitetura geral para a implementação de reconhecedores de padrões espaço-temporais de forma hierárquica e com base no que se sabe do funcionamento do nosso neocórtex

Existem unidades básicas de processamento, cada uma das quais faz exatamente a mesma coisa

O que muda é a camada e a região dentro de uma camada

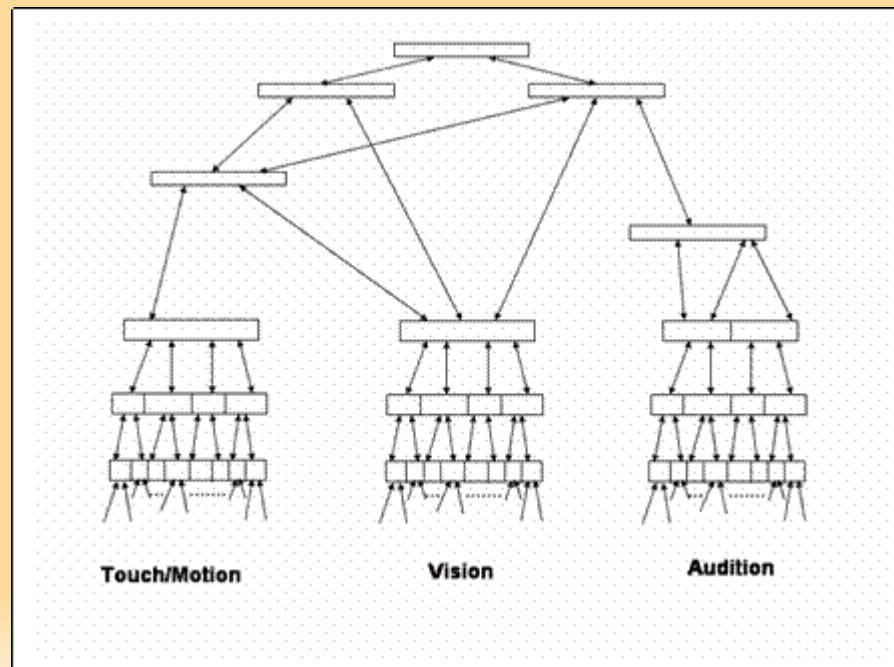
Cada unidade classifica suas entradas tanto espacialmente como temporalmente

Trabalhos Relacionados

Memory-Prediction Framework (cont...)

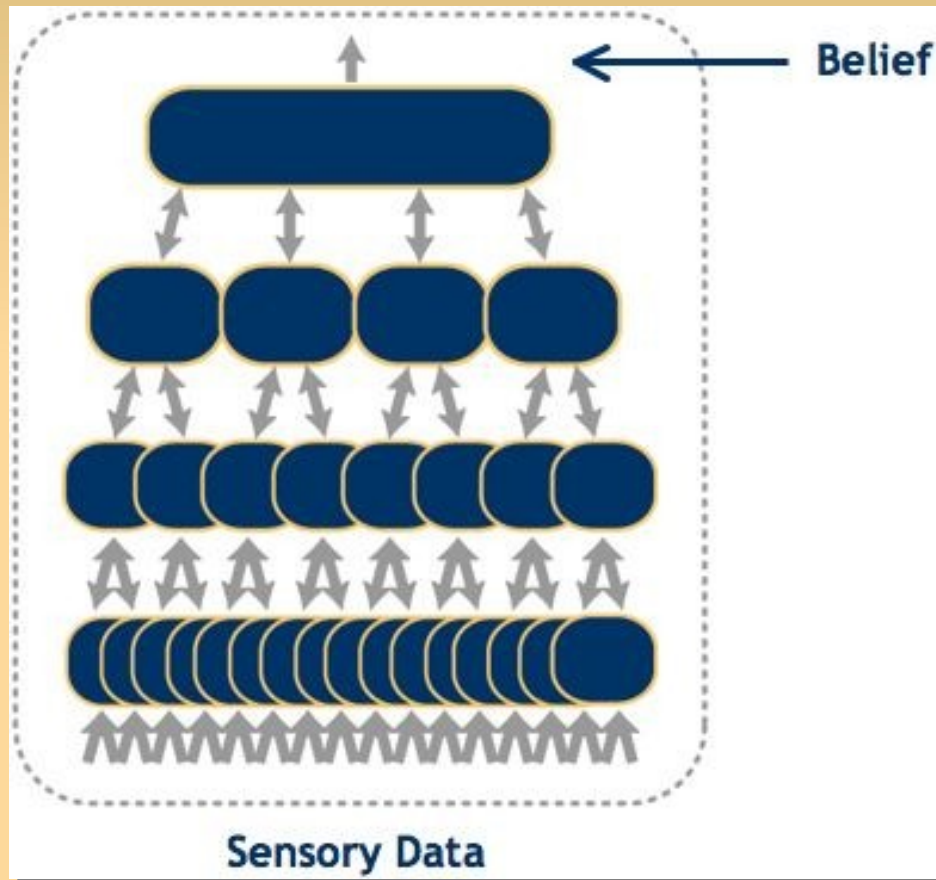
O mundo se move lentamente, portanto certas invariâncias podem ser capturadas utilizando-se da parte temporal

Cada unidade envia seus resultados como entradas para a próxima camada



Trabalhos Relacionados

Hierarchical Temporal Memory (Hawkins 2006)



Implementação Bayesiana do MPF

Pode ser vista como uma Rede Bayesiana Hierárquica com propagação de crenças

Foi aplicada com sucesso em algumas tarefas de classificação de imagens

Atualmente não suporta aprendizado online

Trabalhos Relacionados

Self-Organizing Map (SOM)

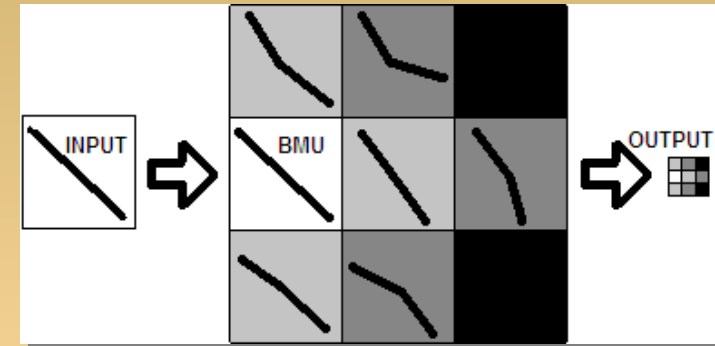
Classifica e reconhece padrões

Reduz dimensionalidade

Preserva topologia do espaço de entrada no espaço de saída

Inspirado no funcionamento do neocórtex (1 camada)

Abordagem neural e que suporta aprendizado online (embora ainda a adaptação automática de parâmetros ainda seja um problema em aberto)



Trabalhos Relacionados

Recurrent Self-Organizing Map (RSOM)

Versão temporal do SOM

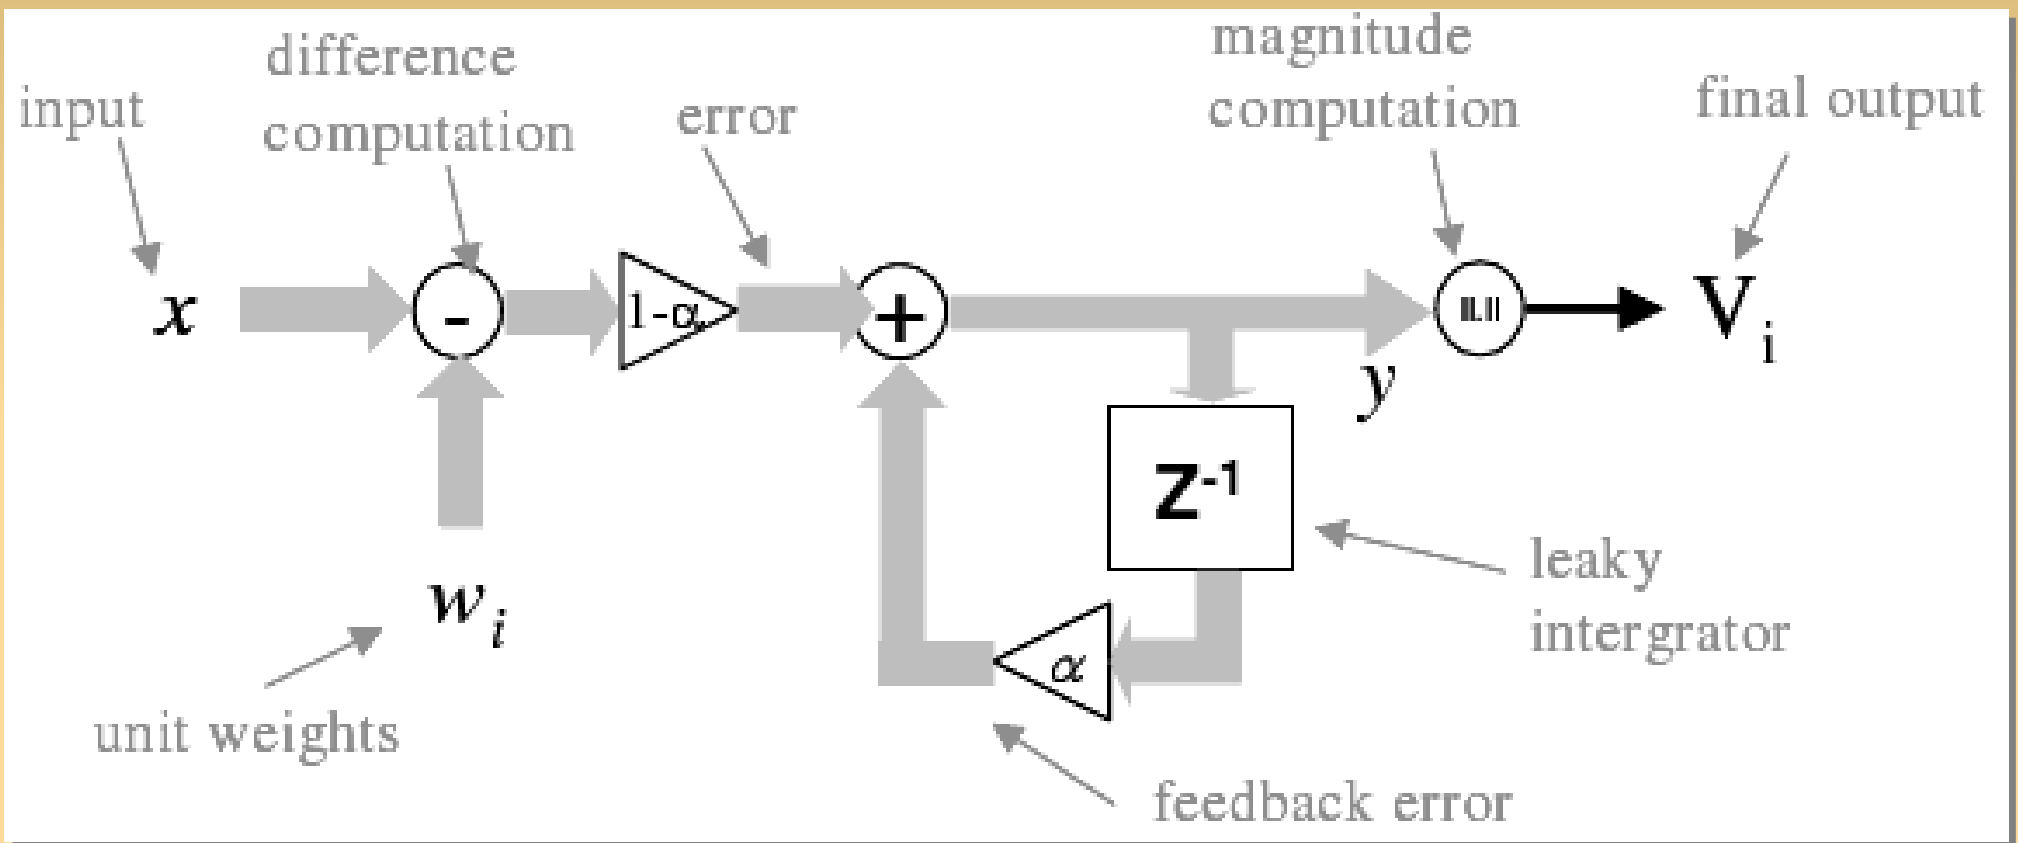
Consegue executar classificação e reconhecimento de padrões temporais através de integradores

Combina resultados passados com atual

Suas capacidades são relativamente limitadas, mas existem outros modelos de mapas auto-organizáveis temporais a serem analisados futuramente (RecSOM, MSOM, AntSOM, etc...)

Requer entradas ortogonais entre si para bom funcionamento

RSOM



Trabalhos Relacionados

Par SOM-RSOM (Miller 2006)

Um SOM recebe um sinal de entrada e o classifica espacialmente

As ativações de seus neurônios formam um vetor de ativações, que é passado como entrada para um RSOM

O RSOM classifica os vetores de ativação temporalmente

Padrões que aparecem próximos no tempo são agrupados, o que trata naturalmente translações, rotações, escala, etc...

Trabalhos Relacionados

Hierarchical Quilted Self-Organizing Map

Vários pares SOM-RSOM organizados hierarquicamente

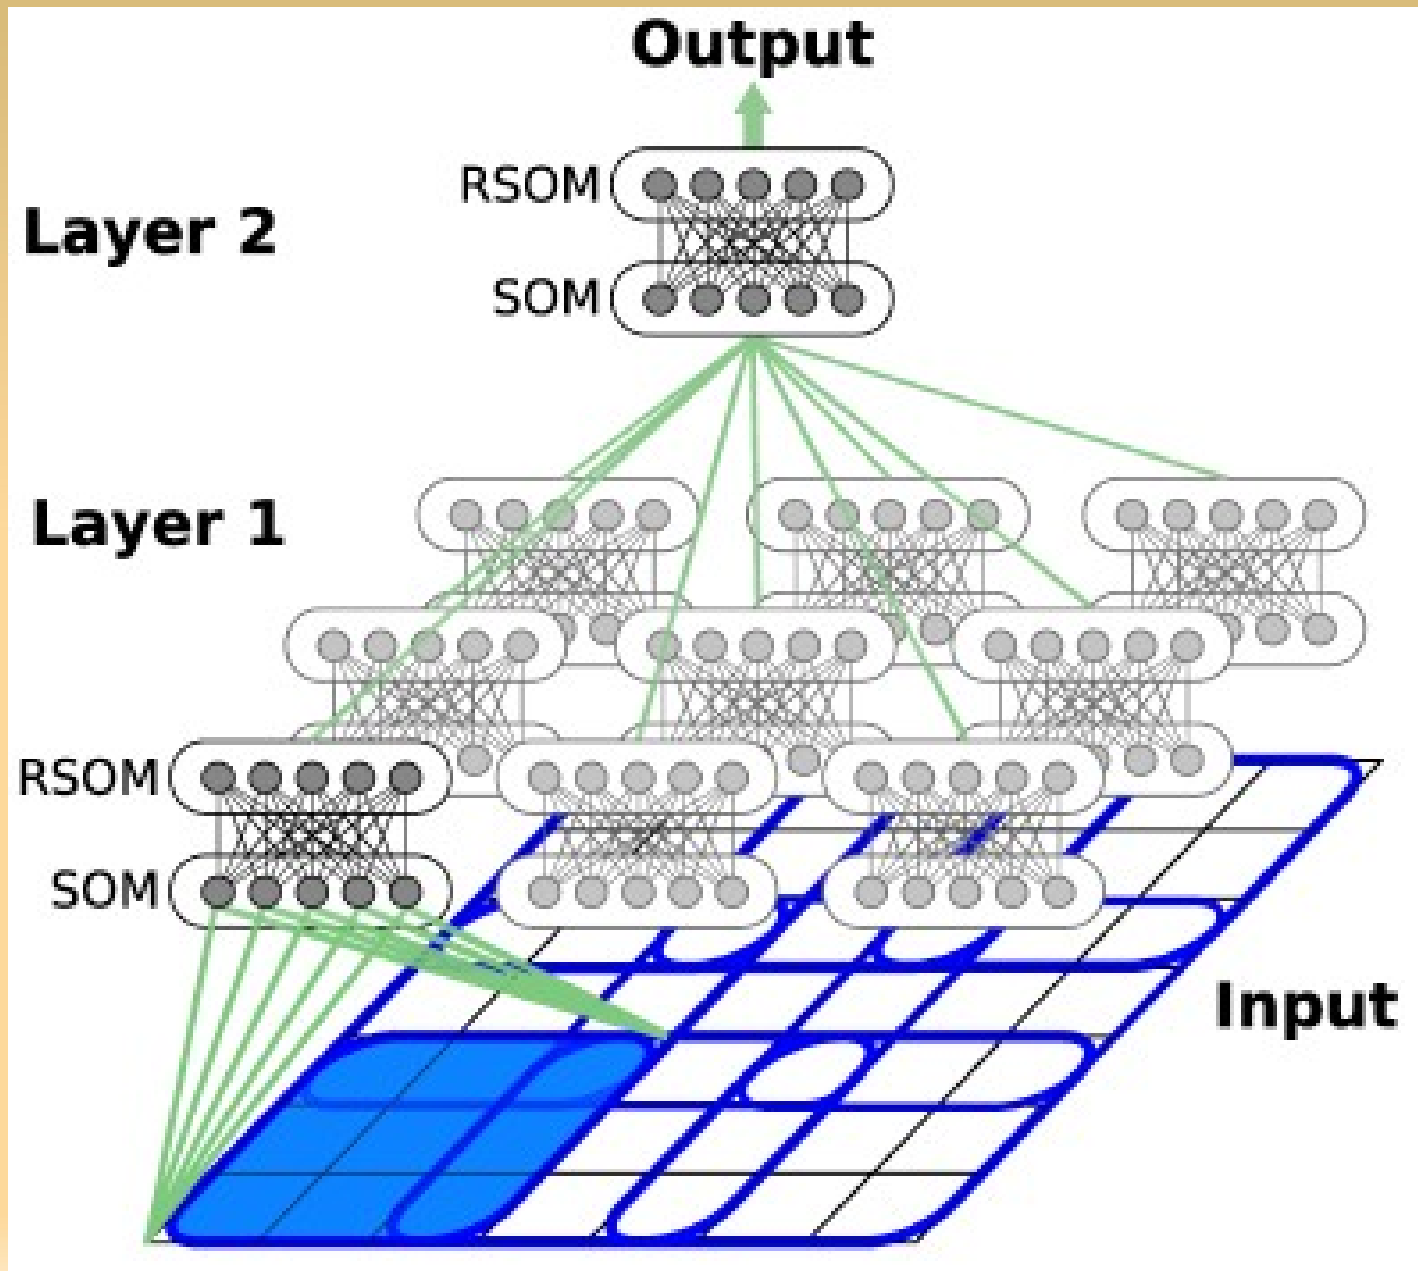
Os índices dos neurônios vencedores de cada RSOM em uma camada são concatenados e enviados como entrada para a camada seguinte

Implementação neural do MPF

Suporta aprendizado online

Porém: Relativamente recente e pouco estudado, há espaço para melhoramentos

HQSOM

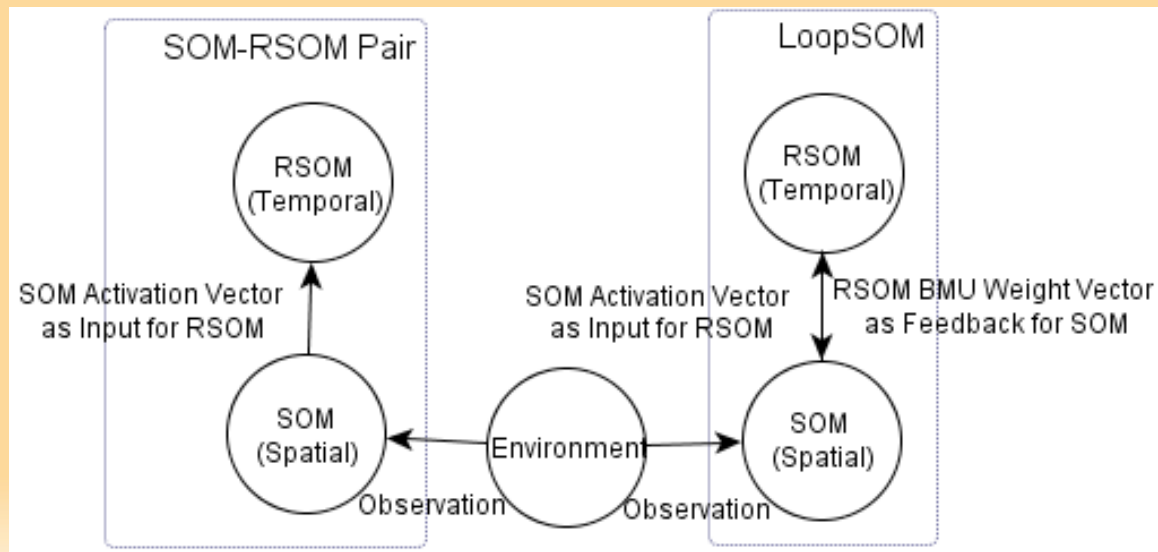


LoopSOM

Processamento temporal do RSOM é usado como preditor para o processamento espacial do SOM

Se o SOM fica em dúvida entre 2 ou mais neurônios vencedores com ativações similares, a predição resolve a ambiguidade

Efetivamente introduz probabilidades a priori não-uniformes para cada neurônio do SOM




Experimentos

4 Pontos 2D: $\{(0,0), (0,1), (1,0), (1,1)\}$

2 Grupos: Esquerda $\{(0,0), (0,1)\}$ e Direita $\{(1,0), (1,1)\}$

Aprendizado congelado depois de formados os 2 clusters

Ponto ambíguo: $(0.5,0.5)$



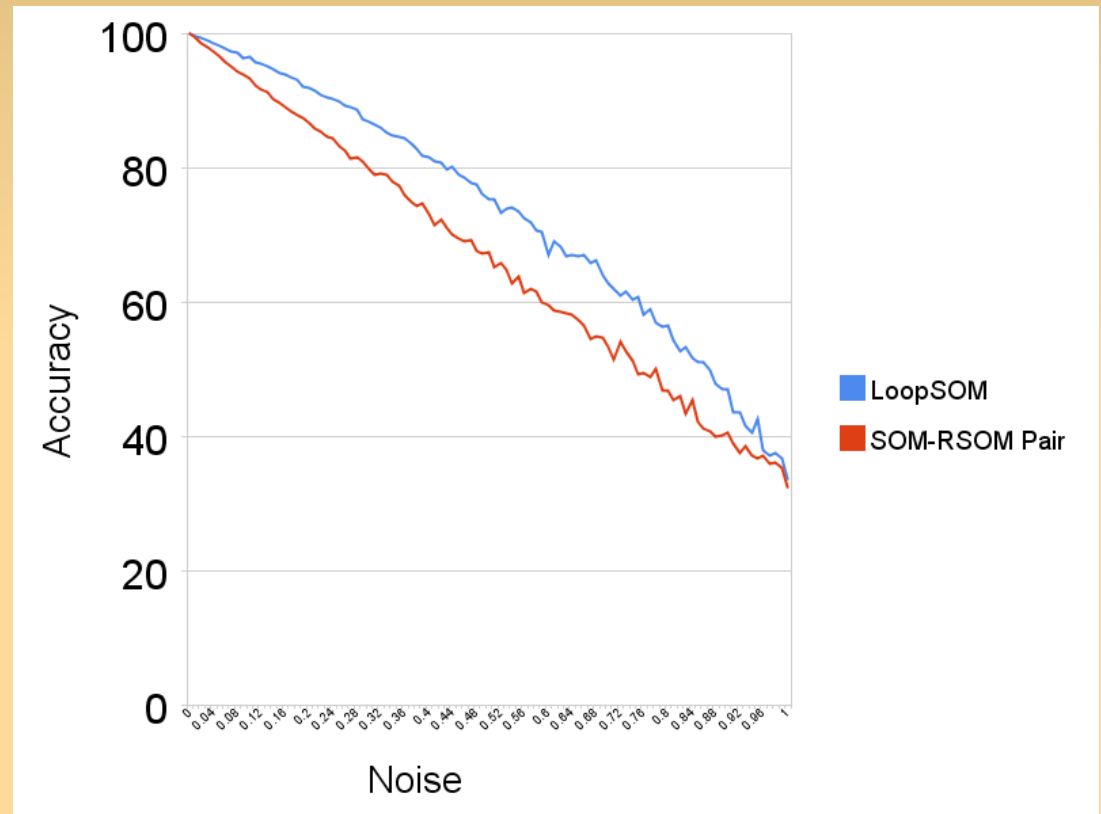
Experimentos

7 Padrões 2D (3x3): 3 linhas verticais, 3 linhas horizontais e padrão vazio

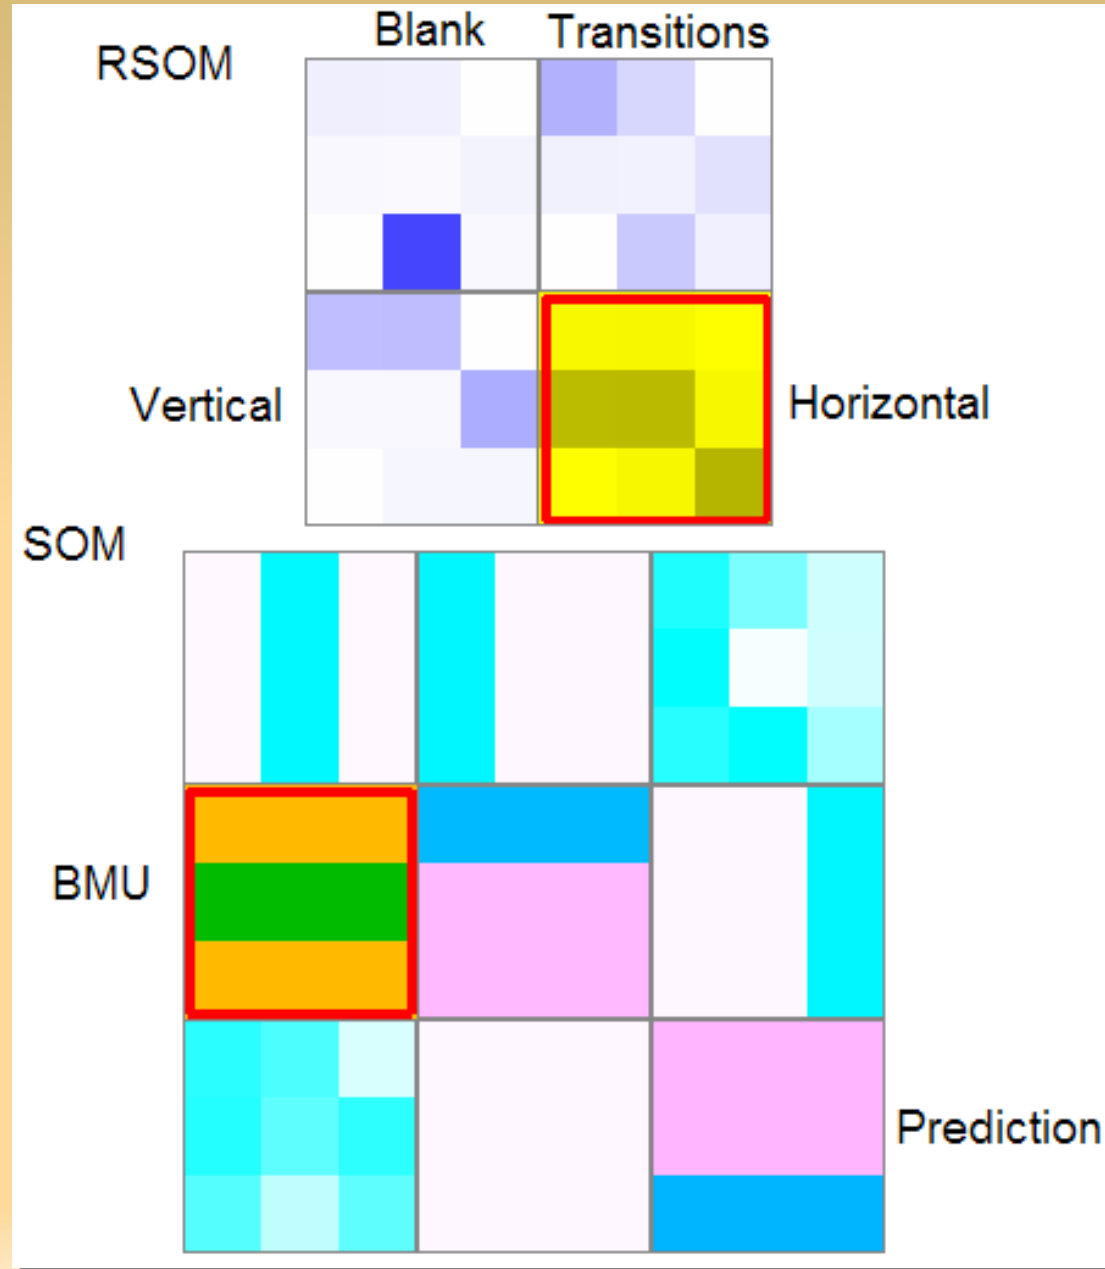
3 Grupos: Vertical, Horizontal e Vazio

Aprendizado congelado depois de formados os 3 clusters

Padrão ambíguo: cruz (+)



Padrões 2D



HQSOM+

Obtido trocando-se os pares SOM-RSOM por LoopSOMs no HQSOM original

Obtem-se um ganho geral de robustez no modelo completo

Muitos parâmetros para ajuste, requer uma análise mais aprofundada futuramente, a fim de obter-se resultados mais estáveis (PLSOM?)

Útil como módulo de reconhecimento e classificação sensorial de qualquer arquitetura mais completa e geral de IA

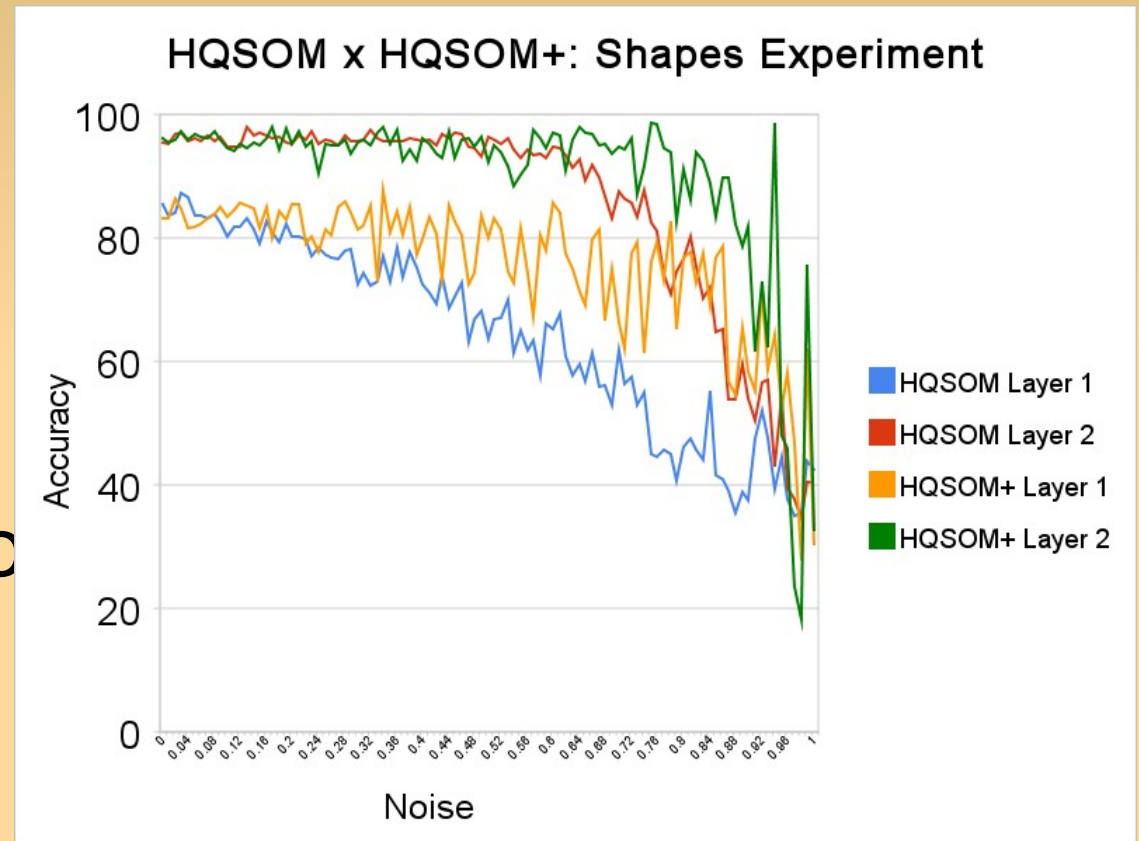
Experimentos

7 Padrões 2D (5x5): 3 linhas verticais, 3 linhas horizontais e padrão vazio

3 Grupos: Vertical, Horizontal e Vazio

Aprendizado congelado depois de formados os 3 clusters

Padrão ambíguo: cruz (+)



Conclusões

O par SOM-RSOM foi aprimorado através de conexões de realimentação, resultando no LoopSOM

O LoopSOM foi aplicado no HQSOM com relativo sucesso

É necessária uma análise mais profunda do ajuste de parâmetros do HQSOM+

Foram feitos experimentos básicos com os novos modelos, obtendo-se resultados satisfatórios

Referências

- BEHNKE, S.; ROJAS, R. Neural abstraction pyramid: a hierarchical image understanding architecture. In: NEURAL NETWORKS PROCEEDINGS, 1998. IEEE WORLD CONGRESS ON COMPUTATIONAL INTELLIGENCE. THE 1998 IEEE INTERNATIONAL JOINT CONFERENCE ON, 1998. Anais. . . [S.l.: s.n.], 1998. v.2.
- BERGLUND, E. Improved PLSOM algorithm. Applied Intelligence, [S.l.], p.1–9, 2009.
- BERGLUND, E.; SITTE, J. The parameter-less SOM algorithm. In: ANZIIS, 2003. Proceedings. . . [S.l.: s.n.], 2003. p.159–164.
- COHEN, L. An information-processing approach to infant perception and cognition. The development of sensory, motor, and cognitive capacities in early infancy, [S.l.], p.277–300, 1998.
- CRISTIANINI, N.; SHAW-TAYLOR, J. An introduction to support vector machines.[S.l.]: Cambridge university press, 2000.
- DEAN, T. A Computational Model of the Cerebral Cortex. 2005. 938p. v.20, n.2.
- ELMAN, J. Finding structure in time. Cognitive science, [S.l.], v.14, n.2, p.179–211, 1990.
- FOLDIAK, P.; ENDRES, D. Sparse coding. , [S.l.], 2008.
- FOLDIAK, P.; YOUNG, M. Sparse coding in the primate cortex. The handbook of braintheory and neural networks, [S.l.], p.895–898, 1995.
- FUKUSHIMA, K. Neocognitron: a self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. Biological Cybernetics, [S.l.], v.36, n.4, p.193–202, 1980.
- GEORGE, D.; JAROS, B.; INC, N. The HTM learning algorithms. March, [S.l.], v.1, p.2007, 2007.
- GUIDE, N. Numenta Platform for Intelligent Computing. , [S.l.], 2008.
- GUIMARAES, G. A taxonomy of Self-organizing Maps for temporal sequence processing. Intelligent Data Analysis, [S.l.], v.7, n.4, p.269–290, 2003.
- HALL, Y. J.; POPLIN, R. E. Using Numentas hierarchical temporal memory to recognize CAPTCHAs. , [S.l.], 2007.
- HAWKINS, J. On Intelligence. [S.l.]: Owl Books, 2005.
- HAWKINS, J.; GEORGE, D. Hierarchical Temporal Memory–Concepts, Theory, and Terminology. Whitepaper, Numenta Inc, May, [S.l.], 2006.
- KOHONEN, T. Self-organization and associative memory. , [S.l.], 1989.
- KOHONEN, T. The self-organizing map. Neurocomputing, [S.l.], v.21, n.1-3, p.1–6, 1998.
- KOSKELA, T.; VARSTA, M.; HEIKKONEN, J.; KASKI, K. Temporal sequence processing using recurrent SOM. 1998. v.1.
- MILLER, J.; LOMMEL, P. Biomimetic sensory abstraction using hierarchical quilted self-organizing maps. In: SPIE, 2006. Proceedings. . . [S.l.: s.n.], 2006. v.6384, p. 63840A.
- MINSKY, M.; PAPERT, S. Perceptrons: an introduction to computational geometry. [S.l.]: MIT press Cambridge, Mass, 1969.
- PINTO, R.; ENGEL, P. LoopSOM: a robust som variant using self-organizing temporal feedback connections. In: TO APPEAR ON PROCEEDINGS OF THE VIII ENIA - BRAZILIAN MEETING ON ARTIFICIAL INTELLIGENCE, 2009. Anais. . . [S.l.: s.n.], 2009.
- RIEDMILLER, M.; BRAUN, H. A direct adaptive method for faster backpropagation learning: the rprop algorithm. In: IN PROCEEDINGS OF THE IEEE INTERNATIONAL CONFERENCE ON NEURAL NETWORKS, 1993. Anais. . . [S.l.: s.n.], 1993.
- RIESENHUBER, M.; POGGIO, T. Hierarchical models of object recognition in cortex. nature neuroscience, [S.l.], v.2, p.1019–1025, 1999.
- SWARUP, S.; LAKKARAJU, K.; KLEMENTIEV, A.; RAY, S.; SASSEN, E.; MUNCHEN, G. An anticipatory self-organized map for robust recognition. In: IASTED INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE AND APPLICATIONS (AIA'05), INNSBRUCK, AUSTRIA, 2005. Proceedings. . . [S.l.: s.n.], 2005.
- SWARUP, S.; LAKKARAJU, K.; SMITH, N.; RAY, S. A Recurrent Anticipatory Self-Organized Map for Robust Time Series Prediction. In: THE WORKSHOP ON SELF-ORGANIZING MAPS (WSOM), PARIS, FRANCE, SEP 5-8, 2005., 2005. Anais. . . [S.l.: s.n.], 2005.
- THORNTON, J.; GUSTAFSSON, T.; BLUMENSTEIN, M.; HINE, T. Robust Character Recognition Using a Hierarchical Bayesian Network. Lecture Notes in Computer Science, [S.l.], v.4304, p.1259, 2006.
- VOEGTLIN, T. Recursive self-organizing maps. Neural Networks, [S.l.], v.15, n.8-9, p.979–991, 2002.