

## Método *Grid-Quadtree* para a seleção de parâmetros do algoritmo *Support Vector Classification* (SVC)

Monica Beltrami\*, Arinei Carlos Lindbeck da Silva†

\* Instituto Federal do Paraná (IFPR)  
Campus Curitiba  
Rua João Negrão 1285, Curitiba, Brasil  
monica.beltrami@ifpr.edu.br

† Universidade Federal do Paraná (UFPR)  
Departamento de Engenharia da Produção  
Centro Politécnico – Jardim das Américas, Curitiba - Brasil  
arineicls@gmail.com

### RESUMO

O algoritmo *Support Vector Classification* (SVC) é uma técnica de reconhecimento de padrões, cuja eficiência depende da escolha de seus parâmetros [1]. Dentre os métodos de seleção de parâmetros do SVC, destaca-se a busca por *grid* (BG), devido à sua simplicidade e bons resultados. Contudo, por avaliar todas as combinações de parâmetros ( $C$ ,  $\gamma$ ) no seu espaço de busca, ela demanda alto tempo de processamento.

A fim de reduzir o número de operações efetuadas pela BG e diminuir o seu custo computacional, propõe-se o método *grid-quadtree* (GQ). O objetivo do GQ é combinar a técnica *quadtree* ao *grid* para identificar a boa região de parâmetros do SVC, evidenciada por [2], evitando avaliações desnecessárias de parâmetros situados nas áreas de *underfitting* e *overfitting*.

Para validar o método GQ, empregaram-se dez bases de dados referência disponíveis em [3]. Os resultados do GQ foram comparados com os da BG observando-se: o número de operações executadas, a taxa de validação cruzada (VC), o número de vetores suporte (VS) e a acurácia do SVC na predição dos conjuntos de teste.

Constatou-se que o GQ encontrou parâmetros ( $C$ ,  $\gamma$ ) com altas taxas VC e baixas quantidade de VS, executando 71,72% a 88,71% menos operações do que a BG. Além disso, verificou-se que para seis das dez bases de dados estudadas a acurácia do SVC-GQ foi superior à do SVC-BG e em duas delas igual. Logo, conclui-se que o GQ é capaz de encontrar parâmetros melhores ou tão bons quanto a BG, realizando menor esforço computacional.

### REFERÊNCIAS

- [1] C. Cortes and V. Vapnik. Support-Vector Networks. *Machine Learning*, **20**, 273 – 297, 1995.
- [2] S. S. Keerthi and C. J. Lin. Asymptotic Behaviors of Support Vector Machines with Gaussian Kernel, *Neural Computation*, **15**, 1166-1189 (2003).
- [3] LIBSVM – A Library for Support Vectors Machines. <https://www.csie.ntu.edu.tw/~cjlin/libsvm>.