



XX Seminário Nacional de Distribuição de Energia Elétrica
SENDI 2012 - 22 a 26 de outubro
Rio de Janeiro - RJ - Brasil

Sérgio Ribeiro Silva	Victor Hugo de Castro Melo
CELG - COMPANHIA ENERGÉTICA DE GOIÁS	CELG - COMPANHIA ENERGÉTICA DE GOIÁS
sergio.rs@celg.com.br	victor.hcm@celg.com.br

Identificação de Arborização sob Rede de Média Tensão Utilizando Reconhecimento de Padrões por Rede Neural Artificial

Palavras-chave

Arborização
Poda de Árvores
Reconhecimento de Padrões
Redes Neurais
SVM

Resumo

Este trabalho apresenta uma metodologia de identificação de arborização sob a rede de média tensão através do uso de imagens de satélite. Um sistema de reconhecimento de imagens baseado em redes neurais foi desenvolvido de forma a permitir identificar os pontos onde haja arborização com alta probabilidade de interferência na rede elétrica. Foram utilizadas Redes Neurais da categoria Máquinas de Vetor de Suporte para classificação juntamente com técnica de reconhecimento de objetos em imagens. O sistema permite identificar automaticamente regiões com grande incidência de arborização sob a rede em áreas urbanas, possibilitando o planejamento da poda de forma bastante objetiva, inclusive aperfeiçoando o dimensionamento das equipes de manutenção.

1. Introdução

A poda de árvores é uma das etapas mais importantes na manutenção preditiva de sistemas de distribuição aéreos. Um elevado número de interrupções no fornecimento de energia está associado à interferência de arborização junto a rede de distribuição de média e baixa tensão. Este problema é especialmente importante em cidades com nível de arborização muito elevado e com significativa predominância de rede de distribuição aérea convencional, como é o caso de Goiânia. Estima-se que capital do Estado de Goiás tenha mais de dois milhões de árvores plantadas em seu território, o que a torna a capital mais arborizada do país com cerca de 0,8 árvores por habitante. Um procedimento de poda de árvores bem elaborado e corretamente

executado é essencial para manter os índices de continuidade de fornecimento de energia dentro das metas estipuladas para o município.

A poda de árvores programada deve ser precedida de um rigoroso planejamento de recursos materiais e humanos, visando garantir que todo o município seja abrangido e que toda interferência seja identificada e corrigida. A CELG Distribuição executa a poda utilizando-se de equipes terceirizadas, contratadas via licitação. A divisão dos lotes é feita por região geográfica e procura-se dimensionar a área total das regiões de forma uniforme. Uma vez realizada esta divisão, considera-se que cada empresa podará aproximadamente o mesmo número de árvores, tornando igualmente próximos os valores faturados para cada contrato.

A abordagem apresentada acima é falha em alguns aspectos, podendo gerar incoerências. A principal delas é que o número de árvores a podar não é necessariamente igual para cada área designada. Outro problema é definir, *a priori*, um número aproximado de podas a executar em cada região, buscando-se garantir que a reserva financeira de cada contrato seja suficiente para executar todo o trabalho. Como consequência, verifica-se, algumas vezes, que os quantitativos de poda não são igualmente distribuídos e, em outros casos, que o valor de reserva financeira do contrato pode não permitir a execução completa do trabalho para determinada região. Atualmente são os registros das podas realizadas em anos anteriores que determinam a quantidade de podas a serem executadas em uma região. Isso tende a perpetuar e aumentar as falhas existentes.

Verifica-se que é premente a necessidade do uso de ferramentas avançadas que permitam uma estimativa mais eficaz e robusta da quantidade de árvores a serem podadas, bem como da identificação das regiões onde há maior concentração delas interferindo na rede de distribuição aérea.

Neste trabalho será apresentada a proposta de um sistema de reconhecimento de padrões que, utilizando de imagens de satélite, busca encontrar pontos onde haja alta probabilidade de interferência de arborização na rede elétrica. Esse processo de identificação trará uma informação segura e confiável, servindo de base para a elaboração de contratos futuros com maior controle da atuação das equipes de poda. O foco principal do trabalho foi a detecção de interferência de arborização na rede de média tensão (MT), padrão 15 kV, que é empregada em Goiânia. O mesmo sistema pode ser usado ainda para detectar a interferência com a rede de baixa tensão, bastando para isso, que sejam alterados alguns parâmetros de entrada.

O reconhecimento de padrões em imagens tem sido usado nos mais diversos campos do conhecimento. Alguns dos mais importantes são: os sistemas de imagens médicas, os de visão computacional e os de segurança. Tem-se como exemplo o processo de identificação de pessoas pelo padrão de cores e formas da íris. O reconhecimento de padrões em imagens de satélite é usado intensamente em pesquisas geográficas e de uso do solo. O campo de aplicação é tão vasto quanto a quantidade de técnicas disponíveis para tratar de cada problema. Neste trabalho optou-se pela utilização das Redes Neurais Artificiais (RNAs), tendo em vista a quantidade enorme de aplicações onde as mesmas apresentam resultados satisfatórios na identificação de padrões em imagens.

Inicialmente será apresentada uma descrição sucinta das Máquinas de Vetor de Suporte, que é uma categoria de classificadores de padrões utilizados em RNAs. Em seguida, será mostrada a metodologia utilizada para extração de características das imagens, que é a etapa essencial para o processo de aprendizado e posterior reconhecimento. O sistema desenvolvido também será apresentado e serão discutidos os resultados alcançados com a aplicação da técnica. As informações para a elaboração deste trabalho foram extraídas da CELG D.

2. Desenvolvimento

2.1. Redes Neurais Artificiais e Máquinas de Vetor de Suporte

Uma rede neural artificial pode ser definida como (HAYKIN, 2001, p. 28):

Uma Rede Neural é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que tem a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso. Ela se assemelha ao cérebro em dois aspectos:

1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizado;
2. Forças de conexão entre neurônios, conhecidas como pesos sinápticos são utilizadas para armazenar o conhecimento adquirido.

Os fatores descritos são altamente desejados para o objetivo da ferramenta que ora se apresenta. A mesma deve ser capaz de, através de um processo de treinamento, aprender a reconhecer em uma imagem de satélite de determinada área urbana, a interferência da arborização existente nos pontos onde a rede de distribuição é ali representada. O conhecimento adquirido pela rede será então usado daí em diante para, através de um processo de generalização, reconhecer todos os outros pontos onde aconteça a mesma situação.

Diversas arquiteturas de RNAs e máquinas de aprendizado são aptas a cumprir a tarefa proposta. Para este trabalho optou-se por utilizar as máquinas de vetor de suporte (SVM de *Support Vector Machines*). As SVMs são máquinas de aprendizado estatístico lineares com propriedades de generalização interessantes (HAYKIN, 2001, p. 349-380). Elas podem ser entendidas como uma implementação do método de minimização estrutural de risco, cuja idéia principal é a construção de hiperplanos como superfície de decisão de tal forma que a margem de separação entre exemplos positivos e negativos seja máxima. As SVMs (BYUN & LEE, 2002) são conhecidas por apresentarem boa capacidade de generalização mesmo em espaços de alta dimensionalidade e sob condições de exemplos de treinamento reduzidas. Elas também (Idem) apresentam desempenho superior a redes neurais típicas baseadas no método tradicional de minimização de risco empírico, tendo sido utilizadas nos mais diversos campos de reconhecimento de padrões tais como: detecção de faces, reconhecimento de caracteres, reconhecimento e detecção de voz, além de inúmeros outros.

O problema de reconhecimento de arborização sob a rede de média tensão se mostrou complexo devido aos inúmeros arranjos possíveis que a rede pode tomar em termos geométricos, bem como as diversas formas planas que árvores podem apresentar quando vistas em fotos de satélites. Esses fatores requerem um processo de reconhecimento robusto e altamente generalizável, tal como aquele notoriamente atribuído às máquinas de vetor de suporte pela literatura disponível.

2.2. Extração de Características em Imagens

Por mais eficientes que sejam as SVMs no que concerne à capacidade de generalização, o reconhecimento de padrões em imagens deve superar a barreira significativa do amplo espaço de dimensionalidade. Em resumo, os arranjos de rede e arborização tomam, sob forma de imagens, um espaço de características muito amplo que dificilmente pode ser representado matematicamente com simplicidade. Quanto maior a dimensionalidade do espaço dos dados de entrada mais dificultoso será o aprendizado e menos eficiente será a classificação posterior. A maioria das aplicações de detecção de objetos em imagens passa pela extração de características principais da imagem (Idem). Esse processo reduz a quantidade de dados de entrada, de forma que a rede não reconhece a imagem em si, mas apenas um resumo das suas principais características. Essas podem ser elementos geométricos da imagem, tais como a posição dos olhos numa face, cores ou qualquer

outro padrão que se repita.

No caso do reconhecimento de arborização sob a rede de média tensão o padrão que repete é a característica visual das folhagens, com algum traço geométrico que o sobreponha. A rede de elétrica pode assumir os mais diversos aspectos geométricos a partir de seu traçado pelas ruas de uma cidade, porém ao passar sobre uma árvore o padrão de linha geométrica reta sobre as folhagens se repetirá, conforme mostrado no arranjo típico da Figura 01. Nessa imagem a rede de distribuição foi desenhada sob uma imagem de satélite usando suas coordenadas georreferenciadas, de forma que a representação é precisa em termos de posição da árvore em relação à rede.



Figura 01 - Arranjo típico de arborização sob a rede de distribuição.

Neste trabalho usou-se uma técnica de redução de características reconhecidamente eficaz na detecção de faces. O método foi apresentado pela primeira (VIOLA & JONES, 2004, p. 137-154) em um artigo clássico que trouxe grandes avanços para a detecção de faces principalmente no campo da velocidade da classificação. Nesse trabalho os autores apresentam um método robusto, porém simples, de extração de características do tipo *Haar* de imagens. O método se baseia no conceito de imagem integral, que é uma representação matemática da imagem original gerada a partir da soma dos valores dos pixels. Nela o valor de um pixel na posição (x,y) é dado pela soma de todos os pixels cujos valores de coordenadas são menores que x e y , ou seja, os pixels na imagem acima e a esquerda de x e de y . A representação da imagem integral $ii(x,y)$ é dada por:

$$ii(x,y) = \sum_{x' \leq x, y' \leq y} i(x',y')$$

A partir da imagem integral diversas características podem ser rapidamente extraídas da imagem a partir de retângulos de seleção. Na Figura 02 são mostradas as quatro características extraídas das imagens usadas neste trabalho:

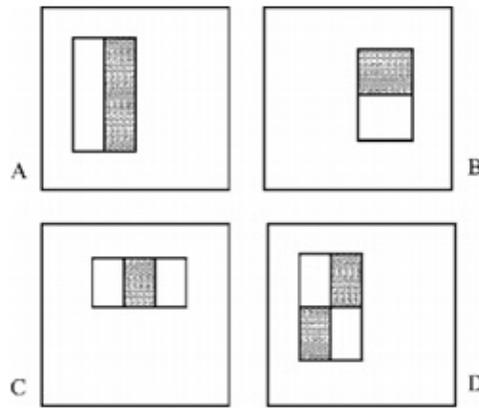


Figura 02 - Características extraídas das imagens através do uso da imagem integral.

As características são obtidas computando-se a diferença dos valores da soma dos pixels dos retângulos brancos pelo valor da soma dos pixels dentro dos retângulos cinza. Na ferramenta desenvolvida as quatro características são retiradas em retângulos de 24x24 pixels e depois de 12x12 pixels, resultando em um total de 776 características para cada imagem de 64x64 pixels utilizada. Este valor é muito inferior ao total de pixels existente para representar a imagem como um todo. No caso em questão, são 4096 pixels para representar uma imagem completa. Comparando-se com as 776 características extraídas (cada característica é um número de ponto flutuante), verifica-se que apenas 19% da quantidade total de informação será realmente utilizada para representar a imagem nas etapas de treinamento e classificação. Porém, estes 19% são as características mais essenciais da imagem e permitirão uma classificação eficiente.

A extração de características conforme descrito se mostrou bastante veloz e eficaz no caso em estudo, permitindo a obtenção rápida de exemplos de treinamento para uso no aprendizado da rede.

2.3. Sistema de Detecção de Árvores sob a Rede de Média Tensão

A Figura 03 resume o funcionamento do sistema de detecção de arborização sob a rede elétrica desenvolvido.

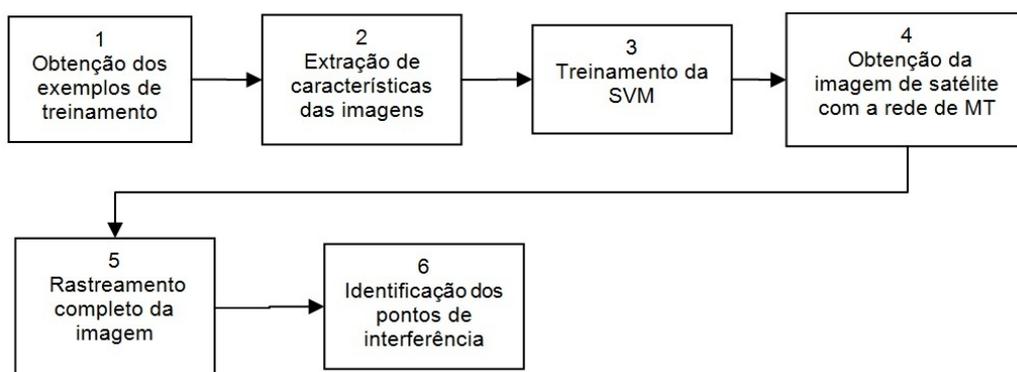


Figura 03 – Etapas do processo de detecção de árvores sob a Rede de Média Tensão.

O sistema foi implementado utilizando o *Matlab* como ambiente de desenvolvimento principal. Esse *software* tem como vantagem fundamental a ampla variedade de funções pré-desenvolvidas para

manipulação matricial e uma excelente gama de ferramentas para o tratamento de imagens. Já a grande desvantagem é o baixo desempenho apresentado na execução do código, tendo em vista que ele é interpretado e não compilado. As imagens foram obtidas do *Google Earth* e a API deste sistema foi utilizada para efetivar a comunicação com o *Matlab*.

Etapa 1 – Obtenção dos Exemplos de Treinamento

Nesta etapa busca-se obter um grande número de imagens que representem a arborização interferindo na rede elétrica. Esses são os chamados exemplos positivos. Busca-se também um número muito grande de imagens que não representem a situação de interesse, os chamados exemplos negativos. Essa é uma das etapas mais trabalhosas do processo, pois o treinamento da rede será mais eficaz em função da quantidade e representatividade de exemplos positivos e negativos apresentados à SVM na fase de treinamento. Na Figura 04 são apresentados alguns casos de exemplos positivos e negativos utilizados.

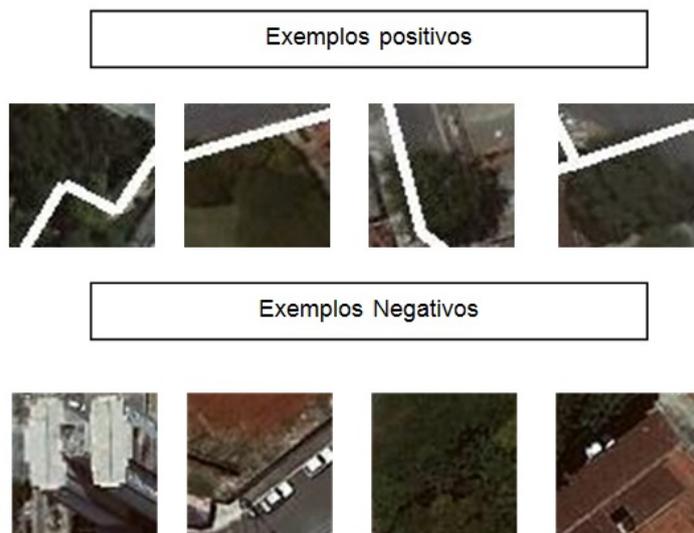


Figura 04 – Exemplos positivos e negativos apresentados à SVM na fase de treinamento.

Etapa 2 – Extração de Características

Utiliza-se um algoritmo para computar a imagem integral de cada exemplo de treinamento e extrair suas características principais. Por padrão são usadas imagens de 64x64 pixels e extraídas 776 características de cada uma delas. Essas são armazenadas em uma grande matriz dividida entre exemplos positivos e negativos. Nesta etapa também é realizado um tratamento prévio das imagens, aumentando o seu contraste e convertendo-as em escala de cinza. As imagens *JPEG* coloridas, por exemplo, necessitam do triplo de informação para serem representadas em sistemas computacionais quando comparadas com aquelas em escala de cinza de mesmas características geométricas. Essa conversão para a escala de cinza é essencial para que a SVM seja capaz de lidar com a imagem em um formato matricial bidimensional. Na figura 05 mostra-se o tratamento prévio que foi dado a exemplo de treinamento.

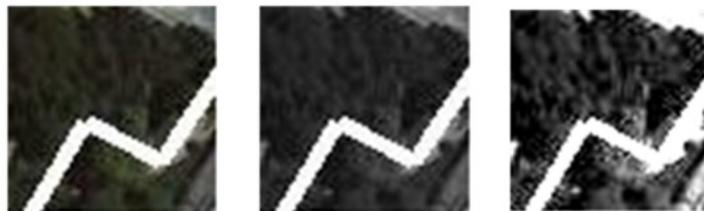


Figura 05 - Tratamento prévio dado a um exemplo de treinamento: no primeiro quadro a imagem original, no segundo a conversão para escala de cinza e no terceiro o ajuste de contraste.

Etapa 3 – Treinamento da SVM

Os exemplos positivos e negativos são sucessivamente apresentados a SVM para que seja realizado o aprendizado. Verifica-se uma grande dificuldade nesta etapa, pois as implementações computacionais de SVM's apresentam um número elevado de variáveis de entrada que devem ser cuidadosamente escolhidas para que o aprendizado alcance os níveis desejados de generalização, minimizando o número de falsos positivos. Essas são situações nas quais a rede reconhece um padrão em uma imagem que na realidade não o contém. Depois de treinada, os parâmetros da SVM foram armazenados para posterior uso na etapa de classificação.

Etapa 4 – Obtenção da Imagem de Satélite com a rede de MT

A rede de Média Tensão da região de interesse é extraída do sistema georeferenciado da CELG D e desenhada sobre a imagem de satélite. O desenho da rede é sempre apresentado em linha espessa. Isso facilita a identificação do padrão, pois uma maior quantidade de pixels é usada para representar a rede. A altitude da representação também deve ser cuidadosamente escolhida, caso contrário as árvores podem assumir na imagem tamanho muito diminuto e não serão reconhecidas pelo classificador SVM. A imagem deve ser ajustada para uma altura padrão de 1300m.

Etapa 5 - Rastreamento Completo da Imagem

A visualização do *Google Earth* é sucessivamente alterada para as regiões de interesse automaticamente pelo sistema. Para cada visualização o sistema captura a imagem na tela e a submete a um rastreamento completo. Nesta etapa janelas de 64x64 pixels são retiradas da imagem e suas características principais são extraídas da mesma forma que a utilizada na fase de treinamento. Essas características são, em seguida, apresentadas a SVM, agora atuando como classificador. A SVM retorna para cada imagem o resultado positivo ou negativo para a identificação do padrão. Se o resultado é positivo o sistema marca aquele ponto com uma janela de formato quadrado de 46x64 pixels.

Etapa 6 – Identificação dos Pontos de Interferência

Após o rastreamento completo da região de interesse o sistema apresentará na tela do *Google Earth* todas as árvores que passam sob a rede de MT. O polígono de localização da árvore é gravado individualmente em um arquivo do tipo *kml*. O número de árvores interferentes será o total de pontos identificados. Nesta etapa o analista do processo tem papel importante, pois falsos positivos sempre são obtidos. Ou seja, a confirmação final dos resultados ainda depende da avaliação do analista responsável. A Figura 06 mostra um modelo de imagem com os pontos de interferência já identificados pelo sistema.



Figura 06 - Modelo de imagem com a representação da rede de MT e identificação dos pontos de interferência (polígonos verdes).

2.4. Testes e Resultados

O sistema foi testado na detecção de pontos críticos de interferência de vegetação na região central de Goiânia. Esta é uma área de grande interesse, pois é consideravelmente arborizada e a poda programada se mostra difícil, principalmente pela dificuldade de acesso com caminhões em dias úteis. Buscou-se verificar em quais condições o sistema seria mais eficaz e em quais ele ainda dependeria de ajustes ou aperfeiçoamentos.

Os principais indicadores a serem considerados para se medir o desempenho do sistema são:

- A taxa de acertos, ou seja, o percentual de pontos de interferência com arborização corretamente identificados em relação ao total de pontos de interferência existentes, e;
- O percentual de falsos positivos, que é obtido a partir do total de falsos positivos encontrados em relação ao total de acertos.

Os testes foram efetuados sempre na mesma região variando-se parâmetros de configuração do sistema, a saber:

- A altitude da visualização a partir do *Google Earth*;
- O grau n do polinômio do *Kernel* usado na SVM (foi utilizada apenas a SVM com *Kernel Polinomial*), e;
- O uso ou não da extração de intensidade de verde nas imagens.

Em todos os casos foram usados no treinamento do sistema 300 imagens de exemplos positivos, mostrando diversas configurações possíveis de rede sobre árvores, e; 600 exemplos negativos, mostrando qualquer parte das imagens de satélite que não tivessem arborização sobre a rede.

Depois de completado o rastreamento das imagens os índices foram obtidos contando-se manualmente os pontos de interferência bem como os acertos e falsos positivos. Como a região de abrangência geográfica do

teste era significativa, a área total foi dividida em 9 imagens, a partir das quais eram obtidos os indicadores de interesse.

Na TABELA 01 estão resumidos os principais resultados para o conjunto de nove imagens na seguinte ordem: o melhor resultado individual, o pior resultado individual e o resultado global obtido pela média dos resultados.

TABELA 01 – Resultados dos testes de avaliação do sistema para nove imagens.

Indicador	Configuração											
	1100m-n ²			1300m-n ²			1300m-n ³			1300m-n ³ (densidade verde)		
	Melhor	Pior	Média	Melhor	Pior	Média	Melhor	Pior	Média	Melhor	Pior	Média
Acerto	94%	13%	69%	94%	40%	75%	92%	71%	80%	100%	67%	80%
Falso positivo	0%	80%	31%	7%	67%	27%	0%	67%	29%	0%	33%	4%

Os resultados mostram que, no atual estágio de desenvolvimento, o sistema apresenta um índice de acerto máximo igual a 80% e uma taxa de falsos positivos de 4%. Na Figura 07 são mostrados exemplos de sucesso na identificação das interferências e na Figura 08 alguns exemplos de falsos positivos.



Figura 07 - Exemplos positivos e algumas falhas na identificação.

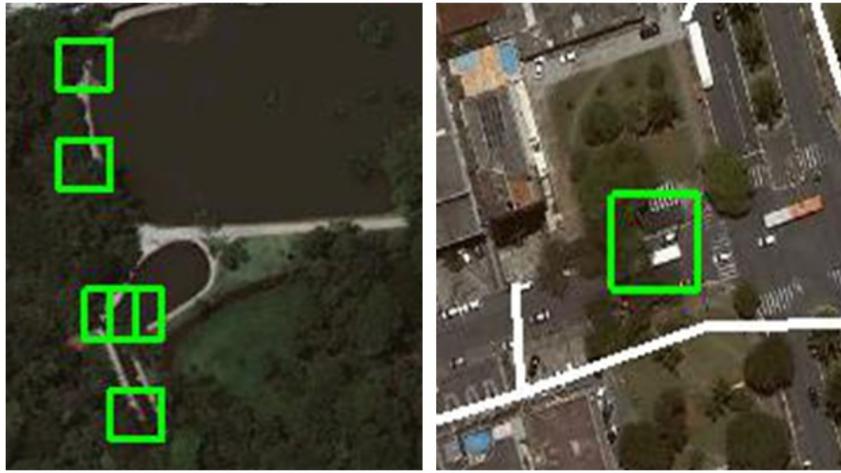


Figura 08 - Exemplos de falsos positivos obtidos.

As principais vantagens apresentadas pelo sistema são:

- Baixo índice de falsos positivos quando se extrai a intensidade de verde da imagem;
- Ótimo nível de acerto para regiões em que ocorrem as interferências mais significativas, ou seja, árvores de grande tamanho exatamente sob a rede;
- A interface com o *Google Earth* permite salvar o resultado da análise no formato *kml*, com cada árvore individualmente identificada e com o total de árvores disponível, e;
- O sistema é altamente configurável e a rede pode ser otimizada para situações diversas alterando-se a composição dos exemplos de treinamento.

As principais dificuldades encontradas para se obter melhores índices de acerto foram:

- Reconhecimento da interferência de árvores pequenas, que cobriam apenas parte da imagem de 64x64 pixels;
- Identificação da interferência parcial. Ou seja, os locais onde apenas parte da árvore está interferindo na rede, e;
- Configurações geométricas em que elementos de cor clara estão próximos às árvores, confundindo-se com a rede.

2.5. Desenvolvimentos Futuros

Os resultados alcançados nos primeiros testes com o sistema indicam que ele poderá evoluir significativamente a partir das seguintes melhorias:

- Otimização dos exemplos de treinamento, adotando-se mais amostras com interferência de árvores pequenas;
- Varrer mais de uma vez cada imagem extraída em escalas diferentes, utilizando-se a mesma janela. Isto permitirá melhorar a identificação de diferentes níveis de interferência;
- Apresentação dos falsos negativos obtidos em uma etapa de identificação como exemplos negativos para a próxima etapa de treinamento;
- Utilizar a intensidade de verde também nas etapas de treinamento e;
- Reescrever o código fonte em uma linguagem que possa ser compilada, o que permitirá uma

velocidade de execução bem maior que a do *Matlab*.

2.6. Aplicações Práticas

No estágio atual de desenvolvimento o sistema já pode ser usado como estimador de quantidade de podas por região, desde que se considere a taxa de acerto média obtida nos testes. É possível também direcionar recursos para regiões onde haja grande percentual de interferência. Para os troncos de alimentadores individuais também já é possível determinar exatamente onde existem pontos de interesse para inspeção das equipes de poda, sem que seja necessário percorrer a rede em toda sua extensão.

3. Conclusões

Os resultados alcançados mostram que a ferramenta é eficaz para o objetivo proposto: a identificação de regiões com alto índice de interferência de arborização com a rede de distribuição. Igualmente importante é o resultado final quantificado em número de árvores, o que permitirá o dimensionamento preciso e confiável dos recursos de poda para cada região do município.

A seleção criteriosa de parâmetros e exemplos de treinamento é fundamental para a qualidade final do resultado obtido. O uso contínuo da ferramenta trará também maiores incrementos, aumentando a sua eficiência e melhorando a confiabilidade dos resultados.

O objetivo do sistema proposto é, de uma forma geral, melhorar a qualidade do serviço prestado pela concessionária de energia. Na medida em que se procura reduzir a interferência da arborização como causa das interrupções no fornecimento de energia, está se melhorando os indicadores de continuidade do serviço, que nada mais são do que representação da satisfação do consumidor.

4. Referências bibliográficas

HAYKIN, S. Redes Neurais: Princípios e Prática. 2. ed. Trad. Paulo Martins Engel. Porto Alegre, Ed. Bookman, 2001, p. 28, 349-380.

BYUN, Hyeran. LEE, Seong-Whan. Applications of Support Vector Machines for Pattern Recognition: A Survey. SVM 2002, LNCS 2388, 2002, p. 213-236.

VIOLA, Paul. JONES, Michael J. Robust Real-Time Face Detection. International Journal of Computer Visions 57(2), 2004, p. 137-154.

VIOLA, Paul. JONES, Michael J. Rapid Object Detection using a Boosted Cascade of Simple Features. ACCEPTED CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION, 2001.

WANG, Qiong. YANG, Jingyu. YANG, Wankou. Face Detection using Rectangle Features and SVM. International Journal of Electrical and Computer Engineering, 2006, p. 1-7.

KHAC, Cuong Nguyen. PARK, Ju H. JUNG, Ho-Youl. Face Detection using Variance based Haar-Like feature and SVM. World Academy of Science, Engineering and Technology, 2009.