

UM ESTUDO COMPARATIVO ENTRE TÉCNICAS DE INTELIGÊNCIA COMPUTACIONAL PARA O RECONHECIMENTO ÓTICO DE CARACTERES MANUSCRITOS

Ubiratan Roberte Cardoso Passos

UCAM – Universidade Cândido Mendes

Avenida Anita Peçanha, 100 - Parque São Caetano, Campos dos Goytacazes - RJ, 28030-335

ubiratanroberte@hotmail.com

Ítalo de Oliveira Matias

UCAM – Universidade Cândido Mendes

Avenida Anita Peçanha, 100 - Parque São Caetano, Campos dos Goytacazes - RJ, 28030-335

italo@ucam-campos.br

Marlito Andrade

UCAM – Universidade Cândido Mendes

Avenida Anita Peçanha, 100 - Parque São Caetano, Campos dos Goytacazes - RJ, 28030-335

marlitopa@gmail.com

Camila do Espírito Santo Ornelas Passos

UCAM – Universidade Cândido Mendes

Avenida Anita Peçanha, 100 - Parque São Caetano, Campos dos Goytacazes - RJ, 28030-335

camilaopassos@hotmail.com

RESUMO

Reconhecer corretamente caracteres manuscritos é uma dos maiores desafios enfrentados pelos pesquisadores que aplicam métodos de classificação e análise de dados, isto devido a sua grande variedade, vários métodos são propostos para resolver este problema apresentando bons resultados. Buscando avaliar estes métodos, três (Redes Neurais Artificiais (RNA); K-Vizinhos mais Próximos (K-Vizinhos) e Máquina de Suporte de Vetores (MSV)) deles foram submetidos a testes estatísticos (ANOVA e TUKEY), comprovando assim a hipótese de que alguma destas ferramentas tem maior aptidão para resolver o problema em relação à outra, ficando os métodos assim classificados pelo teste de Tukey: MSV, RNA e K-Vizinhos em ordem de aptidão, permitindo assim a comunidade científica dedicar seus esforços de forma direcionada.

PALAVRAS CHAVE. Redes Neurais Artificiais, K-Vizinhos mais Próximos, Máquina de Suporte de Vetores, Análise Estatística.

Área principal: Simulação; Metaheurísticas.

ABSTRACT

Properly recognize handwritten characters is one of the biggest challenges faced by researchers who apply classification methods and data analysis, this due to its wide range, various methods are proposed to solve this problem with good results. Seeking to evaluate these methods, three (Artificial Neural Networks (ANN); K-Neighbors More Next (K-Neighbors) and Support Vector Machine (SVM)) of them were subjected to statistical tests (ANOVA and Tukey), thus proving the hypothesis that some of these tools are better able to solve the problem in relation to the other, getting the methods thus classified by the Tukey test: MSV, RNA and K-Neighbors fitness in order, thus allowing the scientific community to devote their efforts directed manner.

KEYWORDS. Artificial Neural Networks , K- Neighbors More Next , Support Vector Machine , Statistical Analysis.

Main area: Simulation; Metaheuristics.

1. Introdução

O reconhecimento óptico de caracteres através da análise de imagens digitais por computadores, tem, a anos despertado atenção da comunidade científica, como se pode observar pelos trabalhos pioneiros de Tauschek, que patenteou a *Optical Character Recognition* (OCR) (Reconhecimento óptico de caractere) em 1929 na Alemanha e em 1935 nos Estados Unidos. A partir da década de 50, as pesquisas a respeito do assunto se intensificaram impulsionadas pelas crescente evolução dos computadores, originando trabalhos como os publicados por (DIMOND, 1957; NEISSER & WENEE, 1960; EDEN, 1961; EDEN & HALLE, 1961; FRISHKOPF & HARMON, 1961) que propunham vários algoritmos para resolução do referido problema.

Devido as diversas formas que um caractere pode possuir, este continua sendo um problema que desperta grande interesse, gerando inúmeras pesquisas sobre o tema, como por exemplo as diversas pesquisas direcionadas ao reconhecimento de caracteres manuscritos, tendo como principal vertente a *Intelligent Character Recognition* (ICR)(Reconhecimento Inteligente de Caracteres) (GONZALEZ & WOODS, 2001; MONTAÑA, 2007; JAIN & KO, 2008; PEREIRA et al., 2010; SHRIVASTAVA & GHARDE, 2010; TRENTINI et al., 2010; LIN et al., 2011).

Muitos algoritmos para reconhecimento de caracteres manuscritos ainda apresentam, em alguns casos, grandes dificuldades em realizar o correto reconhecimento, ou seja, o algoritmo não é capaz de fazer a correta classificação de alguns caracteres, o que interfere no processo de reconhecimento do mesmo (MIRANDA et al., 2013). O grande número de soluções disponíveis, cada qual com suas características e metodologias serviram de inspiração para realização deste trabalho, que tem como principal objetivo avaliar 3, dos mais utilizados métodos para reconhecimento de caracteres, sejam eles manuscritos ou não, são eles: Redes Neurais Artificiais (RNA's), Máquinas de Vetores de Suporte e K-Vizinhos.

O principal objetivo desta análise é verificar, dentre as 3 selecionadas, qual apresenta melhores resultados e em quais casos, buscando desta forma fornecer aos demais pesquisadores parâmetros para concentração de seus esforços nas técnicas que melhor atende à suas necessidades. Todas as ferramentas serão comparadas segundo os mesmos critérios e através da aplicação de métodos estatísticos como poderá ser verificado no decorrer deste artigo.

2. Reconhecimento Óptico de Caracteres

Osório (1991), afirma que os sistemas de reconhecimento óptico de caracteres (*Optical Character Recognition*) – OCR são desenvolvidos para, de certa forma reproduzir a capacidade humana de leitura de textos. Estes sistemas, além de permitirem uma forma alternativa de interação homem-máquina, esta tecnologia é utilizada também para compactação de imagens textuais.

Este último caso é frequentemente aplicado na utilização de sistemas de fac-símile, permitindo a transmissão de compactada de textos. O reconhecimento de caracteres em uma imagem a ser transmitida pelo equipamento em questão, permite a compactação da informação, resultando assim em economia (menor número de informações transmitidas).

Desenvolver sistemas que realizem este tipo de reconhecimento requer várias aplicações tecnológicas, tais como o desenvolvimento de leitoras automáticas de cheques bancários, máquinas automáticas de processamento de códigos postais, máquinas automáticas voltadas ao processamento de formulários preenchidos manualmente, entre outras (AIRES, 2005).

As técnicas de OCR “estabelecem as bases e a motivação para tornar o reconhecimento de padrões e análises de imagens, campos individuais de interesse da ciência” (RODRIGUES E THOMÉ, 2000). Esta técnica é baseada na extração das características dos caracteres de uma imagem de um determinado documento digitalizado, para que possa assim ser realizada a classificação destas características.

Segundo Aires (2005), um fator determinando para o bom desempenho do reconhecimento é a seleção do conjunto de características a serem extraídas dos caracteres. A dificuldade em reconhecer corretamente símbolos ópticos está na complexa irregularidade entre representações gráficas do mesmo caractere, isto devido as variações entre as fontes, estilos e tamanhos. Estas características aumentam quando em se tratando de caracteres manuscritos. Assim sendo, os métodos convencionais de programação de mapeamento de símbolos da imagem em matrizes, analisa pixel e/ou dados do vetor tentando assim decidir qual símbolo corresponde a qual caractere, resultaria em algo nada ou pouco realista.

O reconhecimento de padrões é realizado a todo momento na vida humana. Enfim, reconhecer um rosto, distinguir animais, compreender a fala, ler as mais diversas caligrafias e até mesmo interpretar um exame de eletrocardiografia, tudo isto é reconhecimento de padrões (RIBEIRO, 2003).

2.1. Redes Neurais Artificiais

Redes Neurais Artificiais (RNA's) possuem a característica de serem apropriadas ao reconhecimento de padrões, devido a sua capacidade de aprendizado, modificando seu comportamento frente ao um conjunto de estímulos de entrada (LEOESCH e SARI, 1996). Assim sendo a rede pode aprender a responder especificamente a um determinado conjunto de estímulos fornecidos.

Dadas suas características inerentes, as redes neurais são muito adequadas para o reconhecimento ou classificação de padrões, podendo se adaptar para responder a um padrão específico. Osório (1991) afirma que, redes neurais artificiais representam uma ferramenta computacional de aplicação nas mais diversas áreas da ciência e da vida humana. Dentre as aplicações mais comuns para a aplicação das redes neurais artificiais são: Análise de imagens; Classificação de dados; Diagnóstico médico; Identificação de fraude de cartão de crédito; Processamento de sinais e eliminação de ruídos; Reconhecimento e síntese de fala; Reconhecimento óptico de caracteres (OCR); Robótica.

Esta tecnologia apresentam atributos importantes e únicos, são eles: aproximação universal (mapeamento entrada-saída não linear), capacidade de aprendizado e adaptação ao ambiente em que operam, além da capacidade de generalização.

RNA são modelos matemáticos que buscam se assemelhar às estruturas neurais biológicas com capacidade computacional adquirida por meio de aprendizagem e generalização (BRAGA, 2000). Tais modelos almejam a semelhança com o sistema nervoso dos seres vivos e sua capacidade de processamento de informações, trata-se de uma metáfora à maneira como o cérebro humano processa as informações, no entanto utilizadas na computação.

Haykin (2001) define a rede neural como uma máquina adaptativa, um processador paralelamente distribuído, constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torna-lo disponível para o uso. Para Haykin (2001) essa estrutura se assemelha ao cérebro em dois aspectos: 1 – O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem; 2 – Forças de conexão entre os neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

A arquitetura da rede é definida pela forma na qual os neurônios são organizados e interconectados, ou seja, o número de camadas, o número de neurônios por camada, os tipos de conexões entre estes neurônios e a topologia da rede (HAYKIN, 2001)(SILVA, 2009). Existem diversos modelos para implementação de uma estrutura de Rede Neural Artificial, como a SOM (*Selforganizing map*), RBF (*Radius Basis Function*), LMS (*Least Mean Square*) e MLP (*Multi Layer Perceptrons*).

2.2. Máquinas de Suporte de Vetores

Máquinas de Vetores de Suporte (*Support Vector Machines*), ou SVM's como são mais comumente conhecidas, tem a capacidade de resolver problemas de classificação e regressão, adquirindo com o aprendizado na etapa de treinamento a capacidade de generalização (GUNN,

1998). Considerando um problema binário, o objetivo da SVM é separar as instâncias das duas classes através de uma função que será obtida a partir dos exemplos conhecidos na fase de treinamento. O objetivo é produzir um classificador que funcione de forma adequada com exemplos não conhecidos, ou seja, exemplos que não foram aplicados durante a fase de treinamento, adquirindo desta forma a capacidade de prever as saídas de futuras novas entradas.

O mais simples modelo de SVM, que foi também o primeiro a ser introduzido, é conhecido como Classificador de Margem Máxima. Este modelo trabalha apenas com dados linearmente separáveis, ficando, portanto restrito à poucas aplicações práticas. Entretanto, ainda que com estas limitações, este classificador apresenta propriedades importantes que o torna a pedra fundamental para a formulação de SVM's mais sofisticadas.

A Figura 1(a) apresenta a mostra de espaços de características linearmente separáveis para um conjunto de treinamento bidimensional, enquanto a Figura 1 (b) apresenta um espaço linearmente inseparável. A linha escura presente em ambas as figuras, separando os vetores de entrada de classes distintas é chamada superfície de decisão (ou separação). Em particular, na Figura 1(a) devido a linearidade da superfície de decisão, esta também é conhecida como hiperplano de separação.




FIGURA 1 (a) Espaço linearmente separável




FIGURA 1 (b) Espaço linearmente inseparável

Fonte: Adaptado de (SHRIVASTAVA e GHARDE, 2010)

Logo, o classificador de margem máxima (linhas pontilhadas) otimiza o limites no erro de generalização das máquinas lineares em termos de a margem de separação entre as classes a qual é determinada pelo hiperplano de separação. Essa estratégia envolve separar os dados com um tipo especial de hiperplano.

2.3. K-Vizinhos mais Próximos (*K-Nearest Neighbor*)

Este algoritmo de classificação pode ser inserido no âmbito dos algoritmos de aprendizado baseado em casos (*Case Based Learning*) (AHA, 1991). Logo, este algoritmo baseia-se no princípio que, casos semelhantes deverão a princípio ter a mesma classe. Este princípio de continuidade é de certa forma comum a todos os algoritmos, utilizando o conceito de semelhança de forma direta para determinar a classe. Este algoritmo afere a semelhança entre os pontos através de uma função de distância que é aplicada a pares de casos. É possível definir várias funções de distância, como por exemplo a distância euclidiana, definida pela expressão:

$$\sqrt{\sum (a_i - b_i)^2}$$

e a distância de Manhattan definida pela expressão

$$\sum |a_i - b_i|$$

nas quais, em ambos os casos a_i e b_i representam os valores do atributo i nos casos a e b respectivamente.

Para prever qual a classe de um determinado caso c o algoritmo determina os k casos que menos se distanciam deste. Os casos identificados são denominados **k-vizinhos mais próximos de c** , pode-se então sugerir que: v_1, \dots, v_k . A classe prevista para o caso c , é aquela que ocorre maioritariamente nos seus vizinhos. A expressão a seguir define como essa classe c é determinada:

$$y_c = \arg \max_{cl \in Classes} \|\{v_i: y_{vi} = cl\}\|$$

Pela Figura 2 é possível observar uma breve ilustração de como são feitas as classificações através da aplicação do algoritmo KNN.

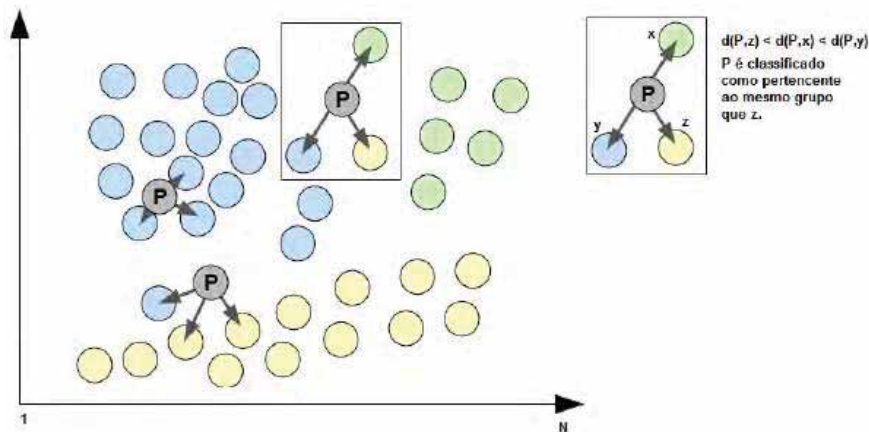


Figura 2 - Classificação de objetos utilizando o kNN com $k = 3$. Fonte: Adaptado de (SANTOS, 2010).

Dada a Figura 2, cada cor representa uma classe, e os círculos marcados com **P** representam os objetos desconhecidos a serem rotulados. Um ponto importante que deve ser considerado é o valor atribuído a k . Caso o valor de k seja pequeno demais, o resultado do algoritmo pode ser sensível a *outliers* (discrepâncias), por outro lado, sendo o valor de k demasiadamente grande, a vizinhança pode incluir muitos pontos pertencentes à classes distintas.

Considerando um conjunto de pontos N como sendo o conjunto de treinamento e um objeto de teste p , o algoritmo calcula a distância $d(N;p)$ entre todos os objetos pertencentes a N , determinando assim uma lista de **k-vizinhos mais próximos**. Uma vez determinados os vizinhos mais próximos, o objeto de teste é classificado baseado na maioria das classes dos **k-vizinhos** mais próximos.

3. Metodologia

Analisando sob o ponto de vista do problema, esta pode ser classificada como uma pesquisa quantitativa, isto pelo fato dos resultados dessa permitirem a classificação e a análise científica, uma vez que é realizada acerca de dados referentes a análise dos resultados obtidos por diferentes técnicas de classificação de dados para o reconhecimento inteligente de caracteres aplicados ao reconhecimento de caracteres manuscritos. Quanto aos meios, essa pesquisa se classifica como bibliográfica e de laboratório, pois a mesma trata simulações realizadas em computador.

Quanto à ótica da natureza e dos fins, essa pesquisa se classifica como metodológica aplicada (VERGARA, 2000) e (MORESI, 2003), pois o estudo está associado aos caminhos, formas, maneiras e procedimentos para se atingir um determinado fim. Também por ser, fundamentalmente, motivada pela necessidade de se resolver problemas concretos, tendo, portanto, finalidade prática. Ao contrário da pesquisa pura que é movida, basicamente, pela curiosidade intelectual do pesquisador e, sobretudo, situada no nível de especulação.

Esta pesquisa pretende testar a seguinte hipótese: das principais soluções (ou das mais aplicadas) para classificação e reconhecimento de caracteres manuscritos, quais delas

apresentam melhores resultados analisando sobre diversas óticas, tais como resultados absolutos, sensibilidade, especificidade e análise de variância juntamente com teste de tukey.

4. Soluções Propostas na Literatura

É possível encontrar a literatura várias soluções para o reconhecimento de caracteres baseados nas mais diversas tecnologias. Das soluções baseadas nas tecnologias de SVM, RNA e K-Vizinhos destaca-se neste artigo os trabalhos de:

Sistemas de reconhecimento automático off-line do alfabeto arábico (indiano) independente, baseado em uma abordagem multi-resolução para extrair características usando o SVM (MAHMOUD e AWADA, 2009). O referido trabalho contou com um banco de dados contendo amostras de 44 escritores, tendo o algoritmo apresentado uma taxa de reconhecimento médio entre 99,00 e 99,83%.

Abaynarh et al. (2012), apresenta em seu trabalho um reconhecedor de caracteres manuscritos irrestrito, baseado em momentos ortogonais e classificadores neurais. O resultado deste trabalho mostra que, se o número de nodos escondidos aumenta, o número de épocas levado em consideração o carácter manuscrito também aumenta. O sistema proposto apresentou taxas de precisão na ordem de 97,46%.

Nasir e Uddin (2013) desenvolveram um método que, baseado em pré-processamentos k-means clustering, teorema Bayesiano e SVM, atingiu taxas de sucesso de até 99,33% para uma amostra de 300 dígitos. Raju (2008) propôs um sistema OCR para caracteres Malayalam. O método de extração e classificação utilizados foram diferentes filtros wavelet e rede MLP, usada somente na classificação. Este sistema obteve taxa média de acerto de 81,3%.

Rahiman e Rajasree (2009), propuseram também um sistema ORC para caracteres Malayalam utilizando Daubechies Wavelet (db4) para extração de características e RNA's para o reconhecimento dos caracteres, este sistema obteve precisão de 92%. Lehal e Singh (2000) apresentaram um sistema de OCR para impressos escritos em Gurmukhi. A extração das características foi realizada utilizando as características estruturais e classificadores em árvores binárias, foi utilizado também o classificador do vizinho mais próximo (k-vizinhos), obtendo precisão de 96,6%.

O método de perfis horizontais e verticais, armazenando altura e largura de cada carácter, para extração de características, utilizando posteriormente redes neurais artificiais para classificação e reconhecimento proposto por Sharma e Jain (2010), obtiveram média 92,78% de precisão média.

Sharma e Jhaji (2010), utilizaram uma imagem normalizada com medida de 48x48 pixels e criaram 64 (8x8) zonas, utilizando densidades de zoneamento como características. Nesta aplicação foram utilizados SVM e K-Vizinhos para classificação e compactação dos resultados. A precisão dos acertos foi de 72,83%.

5. Resultados e Discussões

Os resultados apresentados pelo processo de classificação e reconhecimento de caracteres manuscritos considerou o modelo básico dos métodos (Redes Neurais Artificiais (RNA), Máquinas de Suporte de Vetores (SVM) e K-Vizinhos mais Próximos) analisados (buscando, entretanto suas variações de melhor resultados).

As etapas de treinamento e testes efetuadas nos algoritmos foram realizadas a partir de uma combinação de 26 caracteres escritos por 50 escritores diferentes, sendo possível fornecer assim um total de 1300 caracteres para os processos citados. A Figura 3 apresenta exemplos de possíveis entradas para o propósito deste trabalho.

abril agosto fevereiro novembro
 maio dezembro janeiro março
 janeiro julho junho outubro
 fevereiro abril maio outubro
 agosto julho março setembro
 dezembro junho SETEMBRO
 novembro

Figura 3. Amostra de possíveis entradas para os métodos. Fonte: KAAP, 2004.

A Figura em questão reforça o fato de os métodos terem sido submetidos às mais diversas grafias. Garantiu-se também que todos fossem testados com os mesmos conjuntos de caracteres, permitindo desta forma que as análises fossem realizadas segundo dados pareados. Os procedimentos para preparação e pré-processamento, bem como as particularidades de cada algoritmo não são aqui discutidas, devendo cada um dos mesmos ser estudado separadamente se necessário. Cada algoritmo depois de treinado foi exposto a uma série de testes, totalizando 47, sendo considerados para as comparações em questão os 10 resultados mais expressivos, sendo os resultados de cada método apresentados separadamente nos tópicos a seguir.

5.1. Classificador KNN

Após aplicados os procedimentos necessários, foram obtidos os valores descritos no Quadro 1, apresentado abaixo:

Quadro 1. Resultados para a variação do valor de K

Nº do Teste	Valor de K	Acerto %
1	1	95,15
2	2	94,88
3	3	95,57
4	4	94,99
5	5	94,96
6	6	94,43
7	7	94,36
8	8	94,01
9	9	93,96
10	10	93,56

Fonte: O Autor

A classificação e reconhecimento pelo método K-Vizinhos mais próximos, apresenta evolução inversa ao aumento do valor de K, como pode ser visto no Quadro 1. No entanto, o algoritmo proposto apresenta taxas de acerto de até 95,57%.

5.2. Classificador SVM

Assim como no método anterior, o classificador SVM foi submetido a 10 simulações, tendo como configurações básicas os valores apresentados no Quadro 2, seguidos de sua respectiva taxa de acerto. Para todos os testes foi adotado valor de $\gamma = 0,02$.

Quadro 2. Resultados da Classificação por SVM

Nº do Teste	Valor de C	Kernel	Acerto %
1	1	Linear	95,98
2	2	Linear	97,02
3	3	Linear	97,50
4	4	RBF	97,70

5	5	RBF	97,86
6	6	RBF	97,97
7	7	RBF	98,04
8	8	Polinomial	98,06
9	9	Polinomial	98,08
10	10	Polinomial	98,87

Fonte: O Autor

Após realizados os testes, detectou-se o melhor resultado ao se utilizar o a função Polinomial para o kernel tendo obtido 98,87% de acerto. O Quadro 3 apresenta os melhores resultados para cada uma das funções utilizadas no kernel.

Quadro 3. Resultados da Classificação por SVM

Classificador	Função Linear %	Função RBF %	Função Polinomial %
SVM	97,50	98,04	98,87

Fonte: O Autor

Todos os resultados apresentados em cada uma das etapas do teste serão considerados para análises estatísticas, para desta forma, obter-se melhor avaliação do método.

5.3. Classificador RNA

Para o referido trabalho, foi utilizada uma Rede Neural Artificial – Perceptron Multicamadas composta por três camadas, sendo, uma de entrada, uma oculta e uma de saída. Logo, a RNA utilizada neste projeto possui a seguinte configuração: **camada de entrada** composta de 100 neurônios; **camada oculta** composta de 100 neurônios (valor definido com base nos melhores resultados obtidos nos testes) e **camada de saída** composta de 26 neurônios, um para cada letra do alfabeto brasileiro. Foi utilizada **sigmoide** como função de ativação e 0,7 de taxa de aprendizado.

Os resultados dos testes realizados com a RNA são apresentados no Quadro 4, onde o número de épocas foi alterado de acordo com a cardinalidade do teste.

Quadro 4. Resultados para a variação no número de épocas

Nº do Teste	Épocas	Erro Médio %	Treino %	Teste%	Acerto Médio %
1	800	5,03	96,15	93,80	94,97
2	900	4,93	96,25	93,93	95,07
3	1000	4,87	96,93	94,21	95,13
4	1100	4,66	97,02	94,23	95,34
5	1200	4,55	97,15	94,31	95,45
6	1300	4,42	97,21	94,33	95,58
7	1600	4,23	97,28	94,37	95,77
8	1800	4,07	97,33	94,53	95,93
9	1900	3,62	97,67	95,09	96,38
10	2000	2,89	98,55	95,67	97,11

Fonte: O Autor

O melhor resultado foi apresentado quando o número de épocas foi estendido a duas mil, tendo o algoritmo obtido acerto médio de 97,11%. Foram também realizados testes com números superiores de épocas, entretanto a variação da taxa de acerto não foi significativamente expressiva.

5.4. Comparação Estatística Entre os Métodos

Todos os métodos foram submetidos a várias análises estatísticas, além de comparativos mais simples, como comparação direta entre os resultados, como pode ser observado no Gráfico 1.




Gráfico 1. Comparação direta entre os métodos. Fonte: O Autor

A luz de uma comparação direta nota-se pouca diferença entre as taxas de acerto dos métodos analisados, sendo os melhores apresentados na seguinte ordem, SVM, KNN e RNA respectivamente. No entanto, para que se possa afirmar que um método apesar de apresentar maior taxa de acerto é ou não mais adequado do que outro para o teste realizado, é necessário aplicar outros métodos de comparação estatística, sendo neste trabalho aplicado a Análise de Variância (ANOVA), juntamente com o teste de Tukey para classificação.

Pode-se observar no Quadro 5 o pareamento dos dados obtidos durante os 10 testes realizados em cada um dos métodos analisados. Observa-se também neste quadro o desvio padrão entre os valores.

Quadro 5. Pareamento dos resultados e desvio padrão dos métodos.

	RNA	SVM	KNN
	94,97	96,98	95,05
	95,07	97,3	94,8
	95,13	97,5	95,57
	95,34	97,7	94,99
	95,45	97,86	94,96
	95,58	97,97	94,43
	95,77	98,3	94,36
	95,93	98,5	94,01
	96,38	98,7	93,96
	97,11	98,87	93,56
Soma	956,73	979,98	945,69
Desvio Padrão	0,62946088	0,588859915	0,581488607

Fonte: O Autor

Através do desvio padrão é possível medir o quanto de “dispersão” existe entre os dados em relação à média. Como se pode observar no quadro, os dados tendem a estar próximo à média, o que aumenta a confiabilidade nos resultados. Foi realizada também o cálculo da variância dos dados coletados, sendo o resultado apresentado na Figura 4.

RESUMO

Grupo	Contagem	Soma	Média	Variância
RNA	10	956,73	95,673	0,440246
SVM	10	979,68	97,968	0,385284

KNN 10 945,69 94,569 0,375699

Figura 4. Cálculo da Variância. Fonte: O Autor

O cálculo da variância é fundamental para realização da análise de variância, teste que permite definir e quantificar o quanto uma média é ou não diferença estatística entre as médias comparadas. A Figura 5 apresenta o resultado do teste de análise de variância, juntamente com a classificação realizada pelo teste de Tukey, que permite agrupar os testes em níveis.

ANOVA							TUKEY		
Fonte da variação	SQ	gl	MQ	F	valor-P	F crítica	Amostra	Média	Classificação
Entre grupos	60,13014	2	30,06507	75,08578	9,33E-12	3,354131	SVM	97,968	A
Dentro dos grupos	10,81106	27	0,40041				RNA	95,673	AB
							KNN	94,569	B
Total	70,9412	29							

(a) ANOVA - Análise de Variância

(b) TUKEY - Classificação

Figura 5. Análise de Variância e Classificação por Teste de Tukey: O Autor

O resultado a análise de variância, juntamente com o teste de Tukey demonstram que não existe diferença estatística entre as médias dos métodos SVM e RNA, assim como não existem diferença estatística entre os métodos RNA e KNN. No entanto entre os método SVM e KNN existem estatisticamente diferenças entre as médias.

Os métodos foram testados também quanto a sua especificidade e sensibilidade, sendo os resultados apresentados no Gráfico 2.

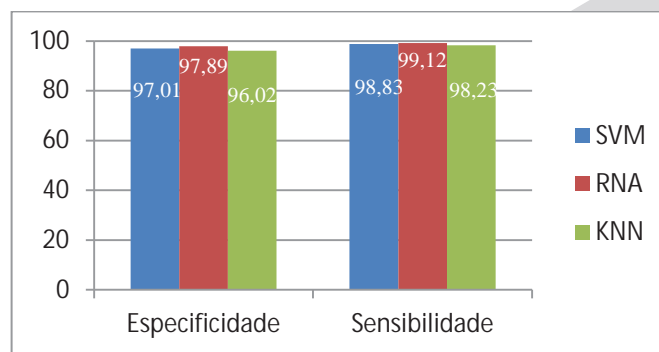


Gráfico 2. Sensibilidade e Especificidade. Fonte: O Autor

A especificidade e sensibilidade medem respectivamente o número de vezes em que os métodos indicaram um carácter e realmente fizeram a indicação correta e quantas vezes indicaram ser outro carácter e não o carácter testado e realmente fizeram uma verdadeira indicação negativa. Testes como estes são frequentemente aplicados em questões relacionadas à diagnósticos, procurando fornecer mais do que dados sobre a taxa de acerto, mas também validar as indicações positivas e negativas.

6. Conclusão

Ao final dos testes foi possível concluir que, os parâmetros obtidos através das operações estatísticas realizadas (ANOVA e TUKEY) indicam não haver diferenças na índice de acertos/aptidão entre as técnicas de SVM e RNA, ainda que estas, a primeira vista apresentem pequenas diferenças em suas taxas de acerto. Entretanto, considerando a comparação entre os métodos de K-Vizinhos e SVM, nota-se que existe, de acordo com o teste de TUKEY, diferenças estatísticas entre os dois métodos, ainda que, semelhantemente ao primeiro caso, as diferenças nas taxas de acerto sejam sutis.

Conclui-se com o estudo que, aprimoramentos nas técnicas estudadas podem levar a resultados mais consistentes, possibilitando inclusive alterações no resultado final do comparativo. Contudo, como neste trabalho foram utilizados os algoritmos em suas formas originais, entende-se que, para solução do problema em questão, tem-se melhor aptidão segundo a escala de TUKEY, os algoritmos na seguinte ordem: SVM, RNA e por fim K-Vizinhos. Desta forma, sugere-se novos testes quanto ao desempenho e custo computacional para execução de cada um dos métodos, buscando desta forma levantar novos parâmetros que sirvam de base para um processo de tomada de decisões quanto da escolha do melhor método para resolução do problema de reconhecimento de caracteres manuscritos.

Referências

- Abaynarh, M.; Elfadili, H.; Zenkour, L.** (2012) "Handwritten Characters Classification Using Neural Networks and Moments Features". *International Journal of Modern Engineering Research (IJMER)* vol. 02, Issue. 5, ISSN: 2249-6645, Sep-Oct. pp-3572-3577.
- Aha, D.W., KIBLER, D., ALBERT, M. K. (1991) "**Instance-based learning algorithms**". *Machine Learning*, 6:37-66.
- Aires, S.B.K.** (2005) "Reconhecimento de caracteres manuscritos baseado em regiões perceptivas". Dissertação (Mestrado em Informática Aplicada) - Pontifícia Universidade Católica do Paraná. Curitiba.
- Braga, A.P.; Carvalho, A.C.P.L.F.; Ludermir, T.B.** (2000) "Redes Neurais Artificiais: Teoria e Aplicações". Rio de Janeiro: LTC.
- Gunn, S.R.** (1998) "Support Vector Machine for Classification and Regression". Technical Report, Faculty of Engineering, Science and Mathematics School of Electronics, University of Southampton. Disponível em: <http://users.ecs.soton.ac.uk/srg/publications/pdf/SVM.pdf>. Acesso em 24 fev. 2015.
- Haykin, S.** (2001) "Redes Neurais: Princípios e Prática". 2.ed. Porto Alegre: Bookman.
- Kapp, M. N.** (2004) "Reconhecimento de Palavras Manuscritas Utilizando Redes Neurais Artificiais". Pontifícia Universidade Católica do Paraná, M. Sc Thesis.
- Lehal, G.S.; Singh, C.** (2000) "A Gurumukhi Script Recognition System". *International Conference on Patterns Recognition*. Los Alamitos. IEEE.
- Leoesch, C.; Sari, S.T. (1996) "Redes Neurais Artificiais: Fundamentos e Modelos". Blumenau: FUB.
- Osório, F.S.** (1991) "Um estudo sobre o reconhecimento visual de caracteres através de redes neurais". Dissertação (Mestrado em Computação) - Universidade Federal do Rio Grande do Sul – UFRG. Porto Alegre.
- Rahiman, M.A.; Rajasree, M.S.** (2009) "ORC for Malayalam Script Using Neural Networks" *Ultra Modern Telecommunications & Workshops. ICUMT 09. International Conference*.
- Raju, G.** (2008) "Wavelet Transform and Projection Profiles in HandWritten Character Recognition – A performance Analysis". *Advanced Computing and Communication. ADCOM. 16th International Conference on IEEE*. p. 309-314.
- Ribeiro, S.R.A.** (2003) "Integração de imagens Lansat TM e dados auxiliares para a classificação automática de unidades fisionômicas/geológicas usando redes neurais". Tese de Doutorado. Universidade Federal do Paraná. 169 p.
- Rodrigues, R.J.; Thomé, A.C.G.** (2000) "Reconhecimento de dígitos cursivos – um método de segmentação por histogramas". In: SIMPÓSIO BRASILEIRO DE REDES NEURAS, 6., Rio de Janeiro, RJ. Anais.
- Sharma, D.; Jain, U.** (2010) "Recognition of Isolated Handwritten Characters of Gurumukhi Script Using Neocognitron". *International Journal of Computer Applications*.
- Sharma, D. Jhaji, P.** (2010) "Recognition of Isolated Handwritten Characters in Gurumukhi Script". *International Journal of Computer Applications*.
- Silva, A.M.** (2009) "Utilização de Redes Neurais Artificiais para Classificação de SPAM". Dissertação (Mestrado em Modelagem Matemática e Computacional). Centro Federal de Educação Tecnológica de Minas Gerais – CEFET-MG. Belo Horizonte.

Mahmoud, S. A.; Awaida, S. M. (2009) "Recognition of off-line handwritten arabic (indian) numerals using multi-scale features and suport vector machines vs. Hidden markov models". The Arabian Journal for Science and Engineering, Vol. 34, n 2B, October.

Moresi, E.D. (2003) "Manual de Metodologia da Pesquisa". Universidade Católica de Brasília. Brasília – DF.

Nasir, M.K.; Uddin, M.S. (2013) "Hand Written Bangla Numerals Recognition for Automated Postal System". IOSR Journal of Computer Engineering (IOSR-JCE). vol. 8, issue 6, jan-feb.

Vergara, S. C. (2000) "Projetos e Relatórios de Pesquisa em Administração". São Paulo: Atlas

