

**RECONHECIMENTO DO PADRÃO PLUVIAL NA CIDADE DE PRESIDENTE  
PRUDENTE – SP ATRAVÉS DE REDE NEURAL ARTIFICIAL**

**RONALDO TOSHIAKI OIKAWA**

**RECONHECIMENTO DO PADRÃO PLUVIAL NA CIDADE DE PRESIDENTE  
PRUDENTE - SP ATRAVÉS DE REDE NEURAL ARTIFICIAL**

**RONALDO TOSHIAKI OIKAWA**

Dissertação apresentada à Pró-Reitora de Pesquisa e Pós-Graduação, Universidade do Oeste Paulista, como parte dos requisitos para obtenção do título de Mestre em Meio Ambiente e Desenvolvimento Regional: Área de concentração: Ciências Ambientais.

Orientador: Prof. Dr. Hamilton Mitsugu Ishiki

006.3  
O39p

Oikawa, Ronaldo Toshiaki.

Reconhecimento do Padrão Pluvial na cidade de Presidente Prudente - SP através de rede neural artificial / Ronaldo Toshiaki Oikawa. – Presidente Prudente, 2015.

113 f.: il.

Dissertação (Mestrado em Meio Ambiente e Desenvolvimento Regional) - Universidade do Oeste Paulista – Unoeste, Presidente Prudente, SP, 2015.

Bibliografia.

Orientador: Hamilton Mitsugu Ishiki

1. Pluviosidade. 2. Redes Neurais Artificiais. 3. Máquina de Vetor de Suporte.

**RONALDO TOSHIAKI OIKAWA**

**RECONHECIMENTO DO PADRÃO PLUVIAL NA CIDADE DE PRESIDENTE  
PRUDENTE - SP ATRAVÉS DE REDE NEURAL ARTIFICIAL**

Dissertação apresentada à Pró-Reitora de Pesquisa e Pós-Graduação, Universidade do Oeste Paulista, como parte dos requisitos para obtenção do título de Mestre em Meio Ambiente e Desenvolvimento Regional - Área de Concentração: Ciências Ambientais.

Presidente Prudente, 16 de Março de 2015.

**BANCA EXAMINADORA**

---

Prof. Dr. Hamilton Mitsugu Ishiki  
Universidade do Oeste Paulista – Unoeste  
Presidente Prudente-SP

---

Prof. Dr. Almir Olivette Artero  
Universidade Estadual Paulista Júlio de Mesquita Filho – FCT  
Presidente Prudente-SP

---

Prof. Dr. Marcos Norberto Boin  
Universidade do Oeste Paulista – Unoeste  
Presidente Prudente-SP

## DEDICATÓRIA

A minha família Adriana Massako Fujiki Oikawa e Laura Namie Oikawa.

A meus pais, Orlando Noriaki Oikawa e Tomoko Yoshino Oikawa.

A minha irmã, Regilene Harumi Oikawa que detêm a força da mulher.

Ao meu irmão, Rodrigo Yoshiaki Oikawa, que admiro muito.

## **AGRADECIMENTOS**

Agradeço a Deus e todas as forças que me guiaram por este percurso, culminando nessa pesquisa;

A minha companheira Adriana, por todo apoio, compreensão, paciência, palavras de consolo e esforço em cuidar da Laura praticamente sozinha, durante o período de dedicação a essa pesquisa.

Ao orientador Doutor Hamilton Mitsugu Ishiki por toda a dedicação, paciência e orientação à pesquisa em todo o percurso do mestrado.

Aos professores Doutores Almir Olivette Artero da UNESP – Universidade Estadual de São Paulo Campus Presidente Prudente e Marcus Tullius Scotti da Universidade Federal da Paraíba, por toda a dedicação e orientação na área de redes neurais artificiais.

Ao professor Doutor Marcos Norberto Boin, por acreditar no meu potencial, pela paciência em contribuir com seu material e seu conhecimento, iluminando essa jornada tão nebulosa em busca da pluviosidade.

Ao professor Doutor José Tadeu Garcia Tommaselli por colaborar no fornecimento dos dados da estação meteorológica da UNESP – Universidade Estadual de São Paulo Campus Presidente Prudente.

Aos professores Doutores Paulo Augusto Manfron e Vagner Camarini Alves pela gentileza em ceder materiais desenvolvidos durante suas vidas de pesquisa.

Aos professores do Mestrado em Meio Ambiente e Desenvolvimento Regional da Unoeste pelas aulas e conhecimentos compartilhados, que abriram minha alma e mente para um novo olhar crítico e diferenciado do mundo em que vivo.

Aos amigos da turma de Mestrado, Anderson M. de Lima, Antônio A. S. Neto, Deigilam C. Esteves, Gabriel R. A. de Toledo (Jorge), Graziella P. O. de Souza, Meire A. Judai, Murilo M. de Angelo, Rodrigo C. de Oliveira, Tamiris G. de Oliveira por proporcionarem ótimos momentos de amizade, felicidade, tristezas, risos, refeições, pesquisas, aprendizagem, interdisciplinaridade e humildade durante esses anos.

A todos que participaram direta ou indiretamente para a construção desse momento maravilhoso do conhecimento.

Toda ação humana, que queira se tornar positiva ou negativa, depende da motivação (Dalai Lama), e quando a criatura desperta para um grande sonho e sobre ele lança toda a força de sua alma, todo o universo conspira a seu favor (Johann Goethe), e com todos os itens a favor, o aumento do conhecimento é como uma esfera dilatando-se no espaço: quanto maior a nossa compreensão, maior o nosso contato com o desconhecido (Blaise Pascal), pois, se acredita que esse é o caminho para a expansão do conhecimento!

## RESUMO

### **Reconhecimento do Padrão Pluvial na cidade de Presidente Prudente - SP através de rede neural artificial**

As Redes Neurais Artificiais são modelos matemáticos não lineares que se assemelham ao cérebro humano, e esta capacidade de aprender foi aplicada no reconhecimento de padrões da chuva na cidade de Presidente Prudente, localizada na região do Pontal do Paranapanema. Através desses cálculos foi possível indicar uma forma alternativa de se reconhecer o padrão da precipitação da chuva. O presente trabalho utilizou dois algoritmos com aprendizagem supervisionada, sendo o primeiro a Rede de Múltipla Camada de Retro Propagação, com 23 neurônios e com uma, duas e três camadas ocultas, já o segundo, a Máquina de Vetor de Suporte (SVM) utilizou o núcleo polinomial, função de base radial e hiper tangente. O conjunto de dados analisados compreende o período de Janeiro de 1996 até Maio de 2012, sendo obtidos do Centro de Previsão de Tempo e Estudos Climáticos (CPTEC). Os resultados demonstraram que a pressão atmosférica, direção do vento, temperatura mínima e umidade relativa do ar são os parâmetros que estão mais relacionados à precipitação da chuva. O modelo SVM, com núcleo função de base radial, utilizando o parâmetro  $\sigma=0,1$  obteve os melhores resultados, apresentando o coeficiente Kappa (resposta), igual a 0,675 para o grupo de teste um, 0,746 para o grupo de teste dois e 0,826 para o grupo de teste três. Estes resultados demonstram a robustez do conjunto de dados e permitiram atingir altos índices de acerto no reconhecimento da precipitação da chuva.

**Palavras-chave:** Reconhecimento de Padrão da chuva, Redes Neurais Artificiais, Máquina de Vetor de Suporte.

## ABSTRACT

### **Recognition of rainfall pattern in Presidente Prudente – SP city by Artificial Neural Network**

The Artificial Neural Networks are nonlinear mathematical models that resemble the human brain, and this ability to learn was applied to recognize the rain patterns in the city of Presidente Prudente, located in the region of Pontal do Paranapanema. Through these calculations, it was possible to indicate another way to rain forecast. This study used two algorithms with supervised learning, the first one the Multiple Layer Network Propagation, with 23 neurons and with one, two and three hidden layers, and the second one the Support Vector Machine (SVM) with polynomial, radial basis function and hyper tangent cores. The set analyzed covers the period from January 1996 to May 2012, collected from Weather Forecast Center and Climate Studies (CPTEC). The results showed that the atmospheric pressure, wind direction, minimum temperature and air relative humidity were the parameters more related with the rain precipitation. The SVM model with base radial function core, using  $\sigma=0.1$ , showed the best results with Kappa coefficient, equal to 0.675 for first test group, equal to 0.746 to the second test group 0.746 and equal to 0.826 for the third test group. These results demonstrate the data set robustness and allowed achieve high accuracy rate in recognition of rain precipitation.

**Keywords:** Recognition of rainfall, Backpropagation, Support Vector Machine.

## LISTA DE SIGLAS

BP	<i>Backpropagation</i>
CPTEC	Centro de Previsão de Tempo e Estudos Climáticos
GEE	Gases de Efeito Estufa
IPCC	Painel Intergovernamental de Mudanças Climáticas
MLP	<i>Multi Layer Backpropagation</i>
OMI	Organização Meteorológica Internacional
OMM	Organização Meteorológica Mundial
ONU	Organização das Nações Unidas
OTM	Observação do Tempo Mundial
RBF	Redes de Função de Base Radial
RNA	Rede Neural Artificial
SVM	<i>Support Vector Machine</i>
VC	Vapnik-Chervonenkis
VP	Verdadeiro Positivo
VN	Verdadeiro Negativo
FP	Falso Positivo
FN	Falso Negativo

## LISTA DE TABELAS

Tabela 1:	Tipos de funções usadas na máquina de vetor de suporte.....	54
Tabela 2:	Representação do Verdadero Positivo, Verdadeiro Negativo, Falso Positivo e Falso Negativo.....	55
Tabela 3:	Número de observações (dados) coletadas por ano, no período de 1996 à 2012. ....	58
Tabela 4:	Descrição das modelagens empregadas e valores dos parâmetros utilizados. ....	65
Tabela 5:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com uma camada oculta para o grupo de teste um.....	68
Tabela 6:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com uma camada oculta para o grupo de teste dois. ....	68
Tabela 7:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com uma camada oculta para o grupo de teste três.....	68
Tabela 8:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com duas camadas ocultas para o grupo de teste um. ....	69
Tabela 9:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com duas camadas ocultas para o grupo de teste dois.....	69
Tabela 10:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com duas camadas ocultas para o grupo de teste três. ....	69
Tabela 11:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com três camadas ocultas para o grupo de teste um.....	70
Tabela 12:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com três camadas ocultas para o grupo de teste dois. ....	70
Tabela 13:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com três camadas ocultas para o grupo de teste três.....	70
Tabela 14:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo função de base radial e parâmetro Sigma igual a 1,5, para o grupo de teste um. ....	71
Tabela 15:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo função	

	de base radial e parâmetro Sigma igual a 1,5, para o grupo de teste dois.....	71
Tabela 16:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo função de base radial e parâmetro Sigma igual a 1,5, para o grupo de teste três. ....	72
Tabela 17:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo função de base radial e parâmetro Sigma igual a 0,1, para o grupo de teste um. ....	72
Tabela 18:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo função de base radial e parâmetro Sigma igual a 0,1, para o grupo de teste dois.....	73
Tabela 19:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo função de base radial e com parâmetro Sigma igual a 0,1, para o grupo de teste três. ....	73
Tabela 20:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo função de base radial e parâmetro Sigma igual a 0,5, para o grupo de teste um. ....	74
Tabela 21:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo função de base radial e parâmetro Sigma igual a 0,5, para o grupo de teste dois.....	74
Tabela 22:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo função de base radial e parâmetro Sigma igual a 0,5, para o grupo de teste três. ....	74
Tabela 23:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo polinomial, com os valores dos parâmetros Power igual a 1,0, Bias igual a 1,0 e Gamma igual a 1,0, para o grupo de teste um.....	75
Tabela 24:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo polinomial, com os valores dos parâmetros Power igual a 1,0, Bias igual a 1,0 e Gamma igual a 1,0, para o grupo de teste dois. ....	75
Tabela 25:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo polinomial, com os valores dos parâmetros Power igual a 1,0, Bias igual a 1,0 e Gamma igual a 1,0, para o grupo de teste três.....	75
Tabela 26:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo	

	polinomial, com os valores dos parâmetros Power igual a 2,0, Bias igual a 0,5 e Gamma igual a 0,5, para o grupo de teste um.....	76
Tabela 27:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo polinomial, com os valores dos parâmetros Power igual a 2,0, Bias igual a 0,5 e Gamma igual a 0,5, para o grupo de teste dois.....	77
Tabela 28:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo polinomial, com os valores dos parâmetros Power igual a 2,0, Bias igual a 0,5 e Gamma igual a 0,5, para o grupo de teste três.....	77
Tabela 29:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo polinomial, com os valores dos parâmetros Power igual a 1,5, Bias igual a 1,5 e Gamma igual a 0,5, para o grupo de teste um.....	78
Tabela 30:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo polinomial, com os valores dos parâmetros Power igual a 1,5, Bias igual a 1,5 e Gamma igual a 0,5, para o grupo de teste dois.....	78
Tabela 31:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo polinomial, com os valores dos parâmetros Power igual a 1,5, Bias igual a 1,5 e Gamma igual a 0,5, para o grupo de teste três.....	78
Tabela 32:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo hiper tangente, com os valores dos parâmetros kappa igual a 0,1 e Delta igual a 0,5, para o grupo de teste um.....	79
Tabela 33:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo hiper tangente, com os valores dos parâmetros kappa igual a 0,1 e Delta igual a 0,5, para o grupo de teste dois.....	79
Tabela 34:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo hiper tangente, com os valores dos parâmetros kappa igual a 0,1 e Delta igual a 0,5, para o grupo de teste três.....	80
Tabela 35:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo hiper tangente, com os valores dos parâmetros kappa igual a 0,5 e Delta igual a 1,0, para o grupo de teste um.....	80
Tabela 36:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo hiper tangente, com os valores dos parâmetros kappa igual a 0,5 e Delta igual a 1,0, para o grupo de teste dois.....	80
Tabela 37:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo hiper	

	tangente, com os valores dos parâmetros kappa igual a 0,5 e Delta igual a 1,0, para o grupo de teste três.....	81
Tabela 38:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com uma camada oculta, para o grupo de teste um.....	83
Tabela 39:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com uma camada oculta, para o grupo de teste dois. ....	83
Tabela 40:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com uma camada oculta, para o grupo de teste três.....	83
Tabela 41:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com duas camadas ocultas para o grupo de teste um. ....	84
Tabela 42:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com duas camadas ocultas para o grupo de teste dois.....	84
Tabela 43:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com duas camadas ocultas para o grupo de teste três. ....	85
Tabela 44:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com três camadas ocultas para o grupo de teste um.....	85
Tabela 45:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com três camadas ocultas para o grupo de teste dois. ....	85
Tabela 46:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com três camadas ocultas para o grupo de teste três.....	86
Tabela 47:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo função de base radial, com o valor do parâmetro Sigma igual a 0,1, para o grupo de teste um. ....	86
Tabela 48:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo função de base radial, com o valor do parâmetro Sigma igual a 0,1, para o grupo de teste dois.....	87
Tabela 49:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo função de base radial, com o valor do parâmetro Sigma igual a 0,1, para o grupo de teste três. ....	87
Tabela 50:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo função de base radial, com o valor do parâmetro Sigma igual a 0,5, para o grupo de teste um. ....	87

Tabela 51:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo função de base radial, com o valor do parâmetro Sigma igual a 0,5, para o grupo de teste dois.....	87
Tabela 52:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo função de base radial, com o valor do parâmetro Sigma igual a 0,5, para o grupo de teste três. ....	88
Tabela 53:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo função de base radial, com o valor do parâmetro Sigma igual a 1,5, para o grupo de teste um. ....	88
Tabela 54:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo função de base radial, com o valor do parâmetro Sigma igual a 1,5, para o grupo de teste dois.....	89
Tabela 55:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo função de base radial, com o valor do parâmetro Sigma igual a 1,5, para o grupo de teste três. ....	89
Tabela 56:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo polinomial, com os valores dos parâmetros Power igual a 2,0, Bias igual a 0,5 e Gamma igual a 0,5, para o grupo de teste um.....	90
Tabela 57:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo polinomial, com os valores dos parâmetros Power igual a 2,0, Bias igual a 0,5 e Gamma igual a 0,5, para o grupo de teste dois. ....	90
Tabela 58:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo polinomial, com os valores dos parâmetros Power igual a 2,0, Bias igual a 0,5 e Gamma igual a 0,5, para o grupo de teste três.....	90
Tabela 59:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo polinomial, com os valores dos parâmetros Power igual a 1,5, Bias igual a 1,5 e Gamma igual a 0,5, para o grupo de teste um.....	91
Tabela 60:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo polinomial, com os valores dos parâmetros Power igual a 1,5, Bias igual a 0,5 e Gamma igual a 0,5, para o grupo de teste dois. ....	91
Tabela 61:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo polinomial, com os valores dos parâmetros Power igual a 1,5, Bias igual a 0,5 e Gamma igual a 0,5, para o grupo de teste três.....	92

Tabela 62:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo polinomial, com os valores dos parâmetros Power igual a 1,0, Bias igual a 1,0 e Gamma igual a 1,0, para o grupo de teste um.....	92
Tabela 63:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo polinomial, com os valores dos parâmetros Power igual a 1,0, Bias igual a 1,0 e Gamma igual a 1,0, para o grupo de teste dois. ....	93
Tabela 64:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo polinomial, com os valores dos parâmetros Power igual a 1,0, Bias igual a 1,0 e Gamma igual a 1,0, para o grupo de teste três.....	93
Tabela 65:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo hiper tangente, com valores dos parâmetros Kappa igual a 0,1 e Delta igual a 0,5, para o grupo de teste um. ....	94
Tabela 66:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo hiper tangente, com os valores dos parâmetros Kappa igual a 0,1 e Delta igual a 0,5, para o grupo de teste dois. ....	94
Tabela 67:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo hiper tangente, com os valores dos parâmetros Kappa igual a 0,1 e Delta igual a 0,5, para o grupo de teste três.....	94
Tabela 68:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo hiper tangente, com valores dos parâmetros Kappa igual a 0,5 e Delta igual a 1,0, para o grupo de teste um. ....	95
Tabela 69:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo hiper tangente, com os valores dos parâmetros Kappa igual a 0,5 e Delta igual a 1,0, para o grupo de teste dois. ....	95
Tabela 70:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo hiper tangente, com os valores dos parâmetros Kappa igual a 0,5 e Delta igual a 1,0, para o grupo de teste três.....	96
Tabela 71:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo hiper tangente, com valores dos parâmetros Kappa igual a 1,5 e Delta igual a 2,0, para o grupo de teste um. ....	96
Tabela 72:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo hiper tangente, com valores dos parâmetros Kappa igual a 1,5 e Delta igual a 2,0, para o grupo de teste dois.....	97

Tabela 73:	Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo hiper tangente, com valores dos parâmetros Kappa igual a 1,5 e Delta igual a 2,0, para o grupo de teste três. ....	97
Tabela 74:	Valores normalizados dos quatro principais elementos relacionados com a chuva do mês de Janeiro de 2012.....	101
Tabela 75:	Representação dos dias que choveram e dias que não choveram em Janeiro de 2012. ....	102
Tabela 76:	Matriz de confusão representando os 30 dias de Janeiro de 2012. ...	102
Tabela 77:	Representação do Verdadeiro Positivo, Verdadeiro Negativo, Falso Positivo e Falso Negativo.....	103

## LISTA DE FIGURAS

Figura 1:	Região do Pontal do Paranapanema, setores VIII e IX estudadas por BOIN (2000).....	34
Figura 2:	Trajetos preferências das massas de ar atuantes no Oeste Paulista - Período de trinta anos (1967-1996).....	35
Figura 3:	Integração de classificação de base genética e detalhamento das unidades climáticas, focando áreas que influenciam o ritmo climático da região de Presidente Prudente (Alm, Allm, Blllm, BIVm $\alpha$ e BIVm $\beta$ ). .....	38
Figura 4:	Representação gráfica da função de ativação do tipo degrau. ....	40
Figura 5:	Representação gráfica da função de ativação do tipo Linear.....	41
Figura 6:	Representação gráfica da função de ativação do tipo sigmóide. ....	41
Figura 7:	Representação simplificada da arquitetura de uma rede neural construída por duas camadas ocultas.....	43
Figura 8:	Representação de uma rede neural Multicamada Perceptron. ....	47
Figura 9:	Representação gráfica do hiperplano linearmente não separável. ....	52
Figura 10:	Representação da chuva diária durante o ano 2009 na cidade de Presidente Prudente, dados da UNESP.....	59
Figura 11:	Representação da chuva diária durante o ano 2010 na cidade de Presidente Prudente, dados da UNESP.....	59
Figura 12:	Representação da chuva diária durante o ano 2011 na cidade de Presidente Prudente, dados da UNESP.....	59
Figura 13:	Representação gráfica em coordenadas paralelas, na qual cada eixo representa uma variável meteorológica.....	63
Figura 14:	Representação gráfica em coordenadas paralelas, na qual cada eixo representa uma variável meteorológica.....	82
Figura 15:	Representação do mês de Janeiro de 2012, 30 dias. ....	100

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>18</b>
1.1	Objetivo .....	20
1.2	Objetivos Específicos .....	20
<b>2</b>	<b>REFERÊNCIAL TEÓRICO DO CLIMA.....</b>	<b>21</b>
2.1	Caracterização da Radiação Solar .....	25
2.2	Caracterização da Temperatura do Ar .....	26
2.3	Caracterização da Umidade do Ar .....	27
2.4	Caracterização da Evaporação e Evapotranspiração .....	29
2.5	Caracterização do Vento.....	29
2.6	Caracterização da Chuva.....	30
2.7	Caracterizações Climatológicas da Área de Estudo .....	31
<b>3</b>	<b>FUNDAMENTAÇÕES TEÓRICAS DA REDE NEURAL ARTIFICIAL.....</b>	<b>39</b>
3.1	Caracterização da Rede <i>Backpropagation</i> .....	46
3.2	Fundamentações da Máquina de Vetor de Suporte .....	49
3.2.1	Hiperplano ótimo linearmente separável .....	51
3.3	Avaliação das redes neurais artificiais classificadoras.....	54
<b>4</b>	<b>MATERIAIS E PROCEDIMENTOS METODOLÓGICOS.....</b>	<b>57</b>
<b>5</b>	<b>EXPERIMENTOS E ANÁLISE DOS RESULTADOS.....</b>	<b>67</b>
<b>6</b>	<b>CONCLUSÕES E TRABALHOS FUTUROS .....</b>	<b>105</b>
	<b>REFERÊNCIAS.....</b>	<b>107</b>
	<b>APÊNDICE A .....</b>	<b>113</b>

## 1 INTRODUÇÃO

A observação e a epistemologia das mudanças climáticas tem sido objeto de vários estudos mundiais, que procuram quantificar e qualificar os cenários climáticos, avaliando seus impactos e propondo medidas de mitigação e de adaptação (AZADI; SEPASKHAH, 2012).

O Painel Intergovernamental de Mudanças Climáticas (IPCC) sugere que as mudanças climáticas têm sido causadas basicamente pelo aumento da temperatura global, que tendem a piorar, caso a humanidade não se articule para controlar a emissão dos gases que causam o efeito estufa (GEE). Em 2007, o IPCC divulgou os resultados do seu Quarto Relatório de Avaliação das Mudanças Climáticas do planeta, denominado IPCC-AR4 (MARENGO, 2007; IPCC, 2007).

Segundo o IPCC (2007) e Marengo (2007), pesquisas demonstram resultados alarmantes para um aumento médio global das temperaturas entre 1,4°C e 5,8°C até o ano de 2100. Já o Quinto Relatório (AR5), liberado em Setembro de 2013, aponta que o vilão deste aquecimento nos dias atuais tem sido o setor de energia, confirmando que a queima de combustíveis fósseis está impulsionando as mudanças do clima (IPCC, 2013). Adicionalmente o processo de urbanização, na qual predomina as atividades industriais, comerciais, transportes e serviços urbanos, provocam alterações desrespeitando as condições ambientais naturais e urbanas (PRIMAVESI; ARZEB; SANTOS, 2007).

Por outro lado, a ocupação e devastação do meio rural representam uma das maiores e mais significativas transformações que a humanidade realiza na paisagem natural. As mudanças do solo, por exemplo, são percebidas por meio da retirada da vegetação original para dar espaço às plantações e pecuária (BRAIDO et al., 2008).

Segundo Braido et al. (2008), na região da cidade de Presidente Prudente, há basicamente o predomínio da monocultura de cana-de-açúcar, que utiliza grande quantidade de agrotóxicos. Este procedimento provoca alterações na paisagem e alterações significativas no comportamento dos elementos climáticos, tais como a temperatura, velocidade/direção dos ventos e componentes hidrológicos, com ênfase na chuva (RUBENS; ADIL, 2000).

Os parâmetros climatológicos, atrelados à modelagem matemática utilizando, por exemplo, as redes neurais artificiais podem auxiliar no reconhecimento da precipitação. Ao se saber se em um determinado dia irá chover ou não, o agricultor, por exemplo, pode se programar para aplicar ou não um defensivo agrícola ou se irá acionar ou não a irrigação.

Devido à importância de saber os instantes que podem ocorrer precipitação de chuva, este trabalho visa obter modelos matemáticos não lineares através da Rede Neural Artificial (RNA), no intuito de reconhecer o padrão de dias chuvosos e dias secos.

Existem vários modelos de redes neurais artificiais disponíveis que podem ser utilizados nas mais diversas aplicações como, por exemplo, na classificação, reconhecimento de padrões, aproximação de funções ou predição (HAYKIN, 2001; KOVÁCS, 1996). Dentre os modelos indicados, as redes de Retro propagação de Múltipla Camada e Máquina de Vetores de Suporte (Support Vector Machine - SVM) serão empregadas neste estudo.

Neste trabalho, no Capítulo 2, estão apresentadas as bases climatológicas, caracterização dos elementos meteorológicos e descrição da climatologia regional. No Capítulo 3 é especificado o funcionamento e desenvolvimento da rede neural artificial, utilizada para realizar a procura do reconhecimento do padrão da chuva na cidade de Presidente Prudente.

Os Subcapítulos 3.1 e 3.2, especificamente, abordam o funcionamento dos modelos matemático e seus núcleos, utilizados neste trabalho. O Capítulo 4 apresenta os procedimentos metodológicos que envolvem esta pesquisa. O Capítulo 5 retrata os experimentos executados, demonstrando todos os resultados alcançados, independente de estarem substancialmente adequados ou relevantes.

E, finalmente no Capítulo 6, relatam-se as Conclusões e os Trabalhos Futuros que esta pesquisa gerou e que pode ser realizado. Na sequência as referências utilizadas para o estudo desta pesquisa e, por fim, apresenta-se o Apêndice A que demonstra o fluxograma dos cálculos realizados neste trabalho.

## 1.1 Objetivo

Este trabalho tem por objetivo geral, analisar e identificar a precipitação da chuva na cidade de Presidente Prudente através de modelos matemáticos utilizando redes neurais artificiais.

## 1.2 Objetivos Específicos

Para o efetivo aprendizado da rede neural artificial e reconhecimento da precipitação da chuva na cidade de Presidente Prudente, foram delineados os seguintes objetivos específicos:

A) Analisar as principais variáveis dos elementos, coletadas na estação meteorológica da cidade de Presidente Prudente (estação número 83716, localizada na latitude -22.12, longitude -51,38), e selecionar as mais relevantes para a precipitação de chuva;

B) Investigar o comportamento da rede neural artificial de múltiplas camadas frente às diversas alterações nas estruturas da rede proposta;

C) Investigar o comportamento do modelo de máquina de vetor de suporte, utilizando-se os núcleos polinomiais, função de base radial e sigmoide, identificando o melhor núcleo que se adapta à identificação da chuva;

D) Aplicar os modelos de redes neurais artificiais para reconhecer o padrão da precipitação das chuvas;

E) Validar os modelos de redes neurais artificiais obtidos, através da criação de grupos de treinamento e testes;

F) Representar e associar a aprendizagem da rede neural artificial em relação á dinâmica do ritmo climatológico.

## 2 REFERÊNCIAL TEÓRICO DO CLIMA

A revisão teórica para a estruturação deste trabalho tem sua fundamentação nos preceitos da meteorologia e climatologia dinâmica, sendo suporte para a compreensão do fenômeno pluviométrico e o ajuste dos principais elementos climáticos utilizados como variáveis de entrada para a modelagem matemática, empregado nesta pesquisa. Assim, relatam-se informações e uma breve história sobre a climatologia.

Dentro das definições mais tradicionais destacam-se as concebidas por Julius Hann (SORRE, 1934 apud SOUZA, 2011, p. 107-115) que define o clima como "[...] um conjunto de fenômenos meteorológicos que caracterizam o estado médio da atmosfera em um ponto da superfície terrestre [...]", Wilhelm Köeppen (KÖEPPEN, 1948), considera clima como "[...] o estado médio e a evolução habitual do tempo de um determinado lugar [...]". Estes são alguns dos autores precursores da meteorologia física. Do outro lado, não contrapondo-se e nem sobrepondo estes conhecimentos, Max Sorre (1934 apud TARIFA, 1981, p. 9) entende o clima como "[...] a série de estados da atmosfera acima de um lugar da Terra, em sua sucessão habitual [...]".

Para Pédelaborde (1970 apud BARROS; ZAVANTTINI, 2009), a Meteorologia Tradicional estuda os elementos atmosféricos separadamente, desta forma recebe a denominação de Meteorologia Analítica, separativa. Esse tipo de abordagem, inicialmente afasta a realidade da atmosférica, pois estuda cada um de seus elementos de forma separada e, só depois, tenta reconstruir, o ambiente como um todo (atmosfera viva). Já a Meteorologia e a Climatologia Dinâmica consideram todos os estados do meio atmosférico (o tempo e as massas de ar) e desta forma, é possível afirmar que ele é sintético e atende melhor às necessidades da Geografia, ciência que se interessa pelas combinações dos elementos (BARROS; ZAVANTTINI, 2009).

De acordo com estas definições citadas no parágrafo anterior, há então um entendimento da existência dos elementos do clima, que são variáveis atmosféricas como temperatura, pressão atmosférica, umidade do ar, pluviosidade, nebulosidade, ventos (direção e velocidade), massas de ar e outros. Ainda nos conceitos, ora citados, os autores ao estabelecerem que o fenômeno climático se dê em um determinado lugar, consideram a importância

dos fatores geográficos, que podem influenciar ou alterar o clima, tais como: altitude, latitude, configuração do relevo, vegetação, influência de oceanos, rios, lagos, correntes marítimas e continentalidade (SORRE, 1934 apud TARIFA, 2001, p. 11-33).

Outro item que corrobora com a análise do clima, é a duração e o período de dados utilizados nos estudos de tempo e do clima, dependendo assim dos objetivos e da escala climática que se pretende adotar, ou seja, as observações podem ser de séculos quando relacionadas às eras geológicas, décadas para caracterizar o clima, ou de períodos de menor duração como meses, semanas ou horas, para analisar interações mais específicas entre superfície e atmosfera (PÉDELABORDE, 1970; SORRE, 1934 apud TARIFA, 2001, p. 11-33).

O tempo e o clima representam combinações realizadas na atmosfera por valores atribuídos à temperatura, umidade relativa do ar, pressão, vento, carga elétrica entre outros, sendo classificado como estados da atmosfera, mas “o tempo, no sentido preciso e perfeitamente definido que os meteorologistas atribuem a esta palavra, é o conjunto de valores que em um dado momento e lugar determinado, caracteriza o estado atmosférico” (PÉDELABORDE, 1970).

Observando sob a visão de Pédelaborde (1970), o clima é definido como o período de tempo (cronológico), que estabelece sobre uma dada região, condições ambientais específicas e, de acordo com a Organização Meteorológica Mundial (OMM), é necessário um período mínimo de 30 anos, para serem definidas estas condições e também denominado de normal climatológica (PÉDELABORDE, 1970).

Os estudos climáticos nas escalas macroclima, mesoclima, clima local e microclima permitem avaliar as mudanças climáticas ocasionadas pelos diversos processos que regulam o clima no planeta. Nesse sentido, uma grande variedade de pesquisas tem sido realizada com o intuito de compreender quais os mecanismos que determinam as mudanças climáticas (AYOADE, 2007).

Outra forma de compreender está voltada à qualidade das variações, que podem ser parcialmente originadas tanto de elementos climáticos como de fatores externos ao sistema climático (AYOADE, 2007). Há

uma variedade de mecanismos em potencial, que podem produzir uma variação do sistema climático, em diferentes escalas de tempo cronológico. Isto se traduz diretamente nas interações não lineares (reações em cadeia) que se produzem entre os diferentes componentes do sistema climático.

Nesse contexto de tempo e clima, a teoria remete a questão da climatologia separativa e climatologia sintética, descrita por Pédelaborde (1970), onde a Climatologia Separativa tem suas bases na Meteorologia Tradicional e apoia-se no conceito que Hann atribuiu ao clima. No método analítico-separatista, cada elemento do clima (temperatura, pressão atmosférica, umidade, precipitações, vento, insolação, nebulosidade, dentre outros) é considerado de forma isolada e, com base nas observações meteorológicas realizadas, calculam-se médias que são utilizadas para a elaboração de cartas e gráficos que, ao separar os elementos climáticos, isolando-os entre si e transformando-os em médias aritméticas, acaba dissociando da realidade (FERREIRA, 2012).

Outros problemas deste método, que se refere aos valores extremos e aos elementos ocasionais, apontam para médias aritméticas que se julgam totalmente mascaradas, distorcendo a realidade. Por isso, a análise analítico-separatista não possibilita a visualização do fenômeno climático em seus processos reais e, assim, do ponto de vista geográfico, o método tradicional apresenta lacunas, uma vez que é estático, ou seja, não é capaz de reconstruir o dinamismo dos fenômenos e suas verdadeiras sucessões de estados, o que impossibilita a reprodução da realidade (SORRE, 1934 apud TARIFA 2001, p. 11-33).

Em contra partida e de acordo com Sorre (1934 apud TARIFA 2001, p. 11-33), a Climatologia Sintética está diretamente ligada à Meteorologia Dinâmica, que analisa o complexo através dos sistemas atmosféricos, isto é, as massas de ar atuantes, preocupando-se, com suas misturas ou iterações. A evolução da Meteorologia Dinâmica e a proposta climática de Sorre (1934 apud, SOUZA, 1981, p. 107-115) possibilitaram novas formas de abordagem em climatologia. É o caso da proposta do “método sintético das massas de ar e dos tipos de tempo”, de Pédelaborde (1970), através da qual, cada tipo de tempo deve ser analisado a partir de seus elementos constituintes, mas sem

extraí-los do conjunto, ou seja, depositar em cálculos que os separariam dos demais componentes do clima.

Esse contexto demonstra que a climatologia está diretamente ligada a meteorologia, ou seja, a climatologia se utiliza dos dados coletados da meteorologia, compondo assim uma análise mais completa do estado do tempo, onde comparece o complexo meteorológico e climático sob os estudos de Hann (1882, apud BLACHE, 1982, p. 2), Sorre (1934, apud SOUZA, 1981, p. 1-25), Pédelaborde (1970), Monteiro (1991), Boin e Zavattini (2000), Sant'anna Neto (2002, 2005), Zavattini (2004), Zavattini e Boin (2013).

A Climatologia Dinâmica, de acordo com Monteiro (1971) é declarada como uma sequência de unidades de tempo, resultando em uma combinação de elementos climáticos diários, ou seja, o ritmo. Monteiro (1971) declara da seguinte forma a climatologia dinâmica:

[...] O ritmo climático só poderá ser compreendido através da representação concomitante dos elementos fundamentais do clima em unidades de tempo cronológico pelo menos diárias, compatíveis com a representação da circulação atmosférica regional, geradora dos estados atmosféricos que se sucedem e constituem o fundamento do ritmo [...] (MONTEIRO, 1971, p. 9).

[...] Só a análise rítmica detalhada ao nível de “tempo” revelando a gênese dos fenômenos climáticos pela interação dos fatores, dentro de uma realidade regional é capaz de oferecer parâmetros válidos à consideração dos diferentes e variados problemas geográficos dessa região [...] (MONTEIRO, 1971, p. 12).

[...] Na análise rítmica as expressões quantitativas dos elementos climáticos estão indissolúvelmente ligados à gênese ou qualidade dos mesmos e os parâmetros resultantes desta análise devem ser considerados levando em conta a posição no espaço geográfico em que se define [...] (MONTEIRO, 1971, p. 13).

Com esses pontos destacados, fica claro que esta visão diferenciada vem complementar a análise do complexo climático, de acordo com as condições e necessidades do Brasil (FERREIRA, 2012), ou seja, de acordo com Monteiro (1971), ao realizar seus estudos de clima, alcançou uma fiel transposição do conceito de Sorre (1934, apud SOUZA, 2011, p. 107-115) sobre o clima, na qual a diferença entre a abordagem de Monteiro e Pédelaborde refere-se a um paradigma presente na concepção de Sorre (1934, apud TARIFA, 1981, p. 1-25).

Com a compreensão da gênese dos fenômenos, a análise da circulação atmosférica regional vem demonstrar a insuficiência dos valores médios dos elementos climáticos, justamente por ocultar o ritmo. Essa combinação dos diferentes elementos do clima e a utilização das sequências de cartas sinóticas do tempo, juntamente com o aperfeiçoamento da classificação genética do clima em termos regionais, Monteiro caracteriza a “análise rítmica”, que consiste na representação do ritmo climático diário (MONTEIRO, 1971).

Nos próximos subcapítulos são esclarecidos alguns elementos considerados importantes para exame do ritmo climatológico que propicia a formação da chuva.

## **2.1 Caracterização da Radiação Solar**

A energia radiativa que a Terra recebe do Sol, está na forma de ondas eletromagnéticas, sendo denominada de radiação solar. Em meteorologia é usual o termo radiação de ondas curtas, em vez de radiação solar. Este fenômeno é considerado uma variável climática muito importante, por ser a principal fonte de energia do planeta e por conta de sua distribuição não uniforme, que acaba influenciando todos os elementos do clima. Adicionalmente, serve como fonte de manutenção do equilíbrio energético dos seres vivos no ecossistema.

Por essa razão, torna-se necessário saber como o balanço de energia ocorre próximo à superfície, disponibilizando a energia radiativa necessária aos processos físicos que ocorrem em superfícies continentais e oceânicas (AYOADE, 2007; ROLIM et al., 2007).

De acordo com Vianello (2000), o intervalo entre o nascer e o pôr-do-sol, é denominado foto período, sendo o tempo máximo que o Sol poderá permanecer brilhando acima do horizonte, em um determinado local. Além do ciclo diurno, produzido pelo movimento de rotação da Terra, a quantidade de radiação solar que atinge o topo da atmosfera terrestre varia de acordo com a época do ano, pois cada uma é caracterizada pela posição da Terra em relação ao Sol.

A declinação solar também é contada a partir do Equador ( $0^{\circ}$ ) em direção aos pólos, para o norte ou para o sul, recebendo os mesmos sinais atribuídos às latitudes de acordo com o hemisfério em que o astro se encontrar naquele instante (latitude norte: sinal positivo; latitude sul, sinal negativo) (ROLIM et al., 2007). Nesse sentido, de acordo com a lei do Cosseno de Lambert, a declinação solar, varia entre  $-23^{\circ} 27'$  (solstício de verão) e  $+23^{\circ} 27'$  (solstício de inverno), influenciando diretamente a duração do dia e da noite, e consequentemente a intensidade da radiação que incide em uma determinada região (MARIN et al., 2008).

Dentro dos preceitos de Ayoade (2007) e Marin et al. (2008), o movimento de translação e inclinação do seu eixo orbital de  $23^{\circ} 27'$  gera as estações do ano, ocasionando posições diferentes em relação à incidência de energia radiante nos hemisférios sul e norte. Com base nesse movimento circular, adota-se algumas posições referenciais, como efemérides, associadas ao início das estações do ano (AYOADE, 2007; MARIN et al., 2008).

## **2.2 Caracterização da Temperatura do Ar**

A temperatura do ar normalmente é medida através de termômetros, baseados no princípio da dilatação de líquidos, pois, o mercúrio se dilata facilmente com o aumento da temperatura. Desta forma, tanto o termômetro de máxima e o de mínima temperatura são instalados horizontalmente para minimizar a movimentação inadequada do mercúrio e do halter, eliminando praticamente os erros humanos durante a coleta de dados (LEMES; MOURA, 2002).

O regime de temperatura de um ecossistema, além de possuir o fluxo de energia térmica entre dois pontos, deve possuir temperaturas diferentes para ocorrer tal fluxo. Assim, o ar é aquecido de baixo para cima, inicialmente por contato e, depois, por convecção, acionado por mecanismos de trocas de contato. Como o ar praticamente não retém as ondas curtas solares, sua temperatura não é consequência da ação direta dos raios do Sol, mas de processos indiretos da reflexão no solo (MARIN et al., 2008).

A fração da radiação solar que é absorvida pelas superfícies, é também a responsável pelo aquecimento do ar, elevando a temperatura. Isso significa que, durante um dia mais frio ou nublado, uma menor quantidade desse calor é transferida para o ar e, em um dia mais quente e seco, há maior quantidade de calor sendo transferida para aquecer o ar e para o ambiente ao redor (LEMES; MOURA, 2002).

A temperatura do solo, além de estar diretamente ligada a transferência de energia, referencia e quantifica a radiação solar que é incidida diretamente, ou sobre um material de cobertura, regulando a biota do solo. Já a temperatura do ar, segundo Ayoade (2007), é um dos elementos mais complexos de estudo, pois a temperatura é expressa pela agitação das moléculas dos gases que a compõe. Desta forma, quanto maior a temperatura, maior será a agitação ou deslocamento das moléculas, sendo que esta agitação depende da pressão atmosférica.

Essa dependência da pressão atmosférica, de maneira simplória permite quantificar a massa de ar ou a quantidade de matéria, em um dado volume. Isto se deve, pois o ambiente com pressão menor tem uma quantidade inferior de moléculas por unidade de volume, implicando diretamente em um menor número de choques das moléculas em contato com o bulbo do termômetro, caracterizando uma temperatura mais baixa (SPIRO, 2009).

### **2.3 Caracterização da Umidade do Ar**

A Umidade do Ar tem importância na determinação do clima, pois a quantidade de vapor d'água contida na atmosfera varia de lugar para lugar, no decorrer do tempo e localidade, apesar de representar apenas 2% da massa total da atmosfera e 4% de seu volume (AYOADE, 2007).

O vapor d'água é o originador de todas as formas de condensação e de precipitação, e absorve a radiação solar desempenhando um papel de regulador térmico no sistema Terra-Atmosfera, o qual retém calor latente, cuja energia é liberada quando o vapor é condensado. Para Manfron et al. (2013) e Marin et al. (2008), este calor latente contido no vapor d'água é a

principal fonte de energia da circulação atmosférica, dando origem a perturbações no globo terrestre.

Há várias formas de se medir a umidade do ar, normalmente sendo utilizadas as seguintes formas, segundo (AYOADE, 2007):

a) Umidade absoluta, expressa em gramas por metro cúbico de ar é a massa total de água num dado volume de ar;

b) Umidade específica, sendo a massa de vapor d'água por quilograma de ar;

c) Índice de massa ou índice de umidade, representando a massa de vapor d'água por quilograma de ar seco;

d) Umidade relativa é a razão entre o conteúdo real de umidade de uma amostra de ar e a quantidade de umidade que o mesmo volume de ar pode conservar na mesma temperatura e pressão quando saturado. Normalmente expressa na forma de porcentagem;

e) Temperatura do ponto de orvalho representa a temperatura na qual ocorrerá saturação se o ar se esfriar em uma pressão constante, sem aumento ou diminuição de vapor d'água;

f) Pressão vaporífica, e a pressão exercida pelo vapor contido na atmosfera em milibares.

Dentre as formas citadas, a umidade relativa do ar é a mais utilizada, pois é de fácil obtenção. A umidade relativa é influenciada pela temperatura do ar, inversamente mais baixa no início da tarde, e mais elevada durante a noite. A umidade relativa não oferece informações sobre a quantidade de umidade presente na atmosfera, mas informa o quão próximo o ar está da saturação (LEMES; MOURA, 2002).

Segundo Marin et al. (2008), a umidade relativa é uma variável que deve ser sempre apresentada em conjunto com a temperatura do ar, pois imaginando um ponto A com umidade relativa média de 70% e um ponto B com umidade relativa de 55%, não é possível concluir que a concentração de vapor d'água é maior no local A do que em B, sem as informações sobre a temperatura dos dois locais.

## **2.4 Caracterização da Evaporação e Evapotranspiração**

A umidade do ar está diretamente ligada à evaporação e evapotranspiração, pois é através da evaporação da água, do solo nu, das superfícies aquáticas e da transpiração das plantas que se compõe a umidade do ar. A evaporação é o processo pelo qual a umidade, em sua forma líquida ou sólida é passada para a forma gasosa, ou seja, vapor d'água (PEREIRA; NOVA; SEDIYAMA, 1997).

A evaporação descreve a perda de água das superfícies aquáticas ou do solo nu, enquanto que a evapotranspiração descreve a perda de água da superfície da vegetação, na qual a transpiração tem importância fundamental. Em outras palavras, a evapotranspiração é um processo combinado de evaporação e transpiração (SOUSA et al., 2010).

Segundo Pereira, Nova e Sediyaama (1997), Akemi e Dias (1999) e Alencar et al. (2011), a evapotranspiração é toda a quantidade de água contida na superfície e, ou interna do solo, transferida para a atmosfera na forma de vapor. A perda de água de um solo vegetado, sem déficit hídrico, num determinado período é a quantidade de água possível que a planta pode e deve utilizar, estabelecendo o nível ideal de relacionamento entre planta, solo e atmosfera. Nesse contexto a evapotranspiração potencial de referência não depende das características e propriedades físicas do solo, mas apenas dos elementos climáticos.

Ainda dentro deste contexto de acordo com Akemi e Dias (1999) e Sousa et al. (2010), quanto maior a temperatura e a velocidade do vento, menor a umidade relativa, assim maior será a evapotranspiração de referência. Em contra partida, quanto a maior evapotranspiração de referência, maior o consumo de água pelas espécies vegetais dominantes de uma determinada região.

## **2.5 Caracterização do Vento**

O vento é um elemento meteorológico diferente, pois trata de grandezas vetoriais nas quais são necessárias velocidades e a direção, caracterizando-o como componente horizontal do vetor velocidade, já que as

massas podem se deslocar verticalmente, sendo chamadas de correntes ascendentes e descendentes (LEMES; MOURA, 2002; MARIN et al., 2008).

O equipamento que mede o movimento da massa de ar (vento) é o anemômetro, que é um sensor mecânico, constituído de três ou quatro conchas ou hélice, sendo que cada rotação gera um pulso elétrico que é captado por um sistema de aquisição eletrônico de dados.

A velocidade do vento é expressa em metros por segundo ( $m.s^{-1}$ ) ou quilômetros por hora ( $km.h^{-1}$ ) ou knot (kt), unidade utilizada em alguns ramos de atividade como unidade de expressão da velocidade do vento ( $1knot=0,514 m.s^{-1}$ ) (AYODE, 2007).

Para Ayoade (2007) e Rolim et al. (2007), tanto a velocidade, bem como a direção do vento, ocorrem de acordo com o transporte de calor associado aos deslocamentos horizontais. Os deslocamentos horizontais são denominados de advecção, em oposição à convecção que estão associados aos movimentos verticais.

O calor do sol aquece a Terra e o ar, em contato com esse calor, se propaga tornando-se mais leve devido à elevação da temperatura. O ar frio ocupa o lugar do ar que se elevou e também se eleva, e assim sucessivamente, formando a movimentação de corrente de ar. Essas correntes de ar (vento) podem ser quentes ou frias, dependendo da estação do ano e da latitude.

## 2.6 Caracterização da Chuva

A precipitação, na forma de chuva, neve e granizo, é o principal mecanismo natural de restabelecimento dos recursos hídricos na superfície terrestre, além disso, a água é o componente principal na manutenção dos organismos vivos e um dos fatores que condiciona o tipo de vida de uma região (TUBELIS; NACIMENTO, 1937).

Existem precipitações na forma pluvial (chuva), de granizo e neve, sendo que, na forma pluvial é necessário que o ar ascenda até altitudes elevadas, para então precipitar na forma de gotas. Este ar ascendente deve ser úmido e a precipitação pluvial deve vencer a força ascendente. Este processo é útil para explicar a importância dos núcleos de condensação, que são

moléculas ou partículas de poeira ou aerossóis que facilitam o agrupamento das pequenas gotículas, presentes nas nuvens, em gotas maiores e mais pesadas, com massa suficiente para precipitar (SPIRO, 2009).

A formação da chuva ocorre de três formas principais, a primeira é denominada chuva convectiva, que está associada à presença de nuvens denominadas cumulus e cumulonimbus. Este tipo é causado pelo movimento vertical de uma massa de ar, decorrente da expansão e redução da densidade das massas de ar aquecida pela radiação solar, que está próxima da superfície do solo mais quente. Desta forma, a precipitação tem alta intensidade, duração relativamente curta e ocorre normalmente nos finais de tarde e inícios de noite, ocorrendo também geralmente durante a primavera e o verão, pois é nesses períodos que o movimento convectivo das massas de ar é mais intenso por causa da maior disponibilidade de energia radiante (TUBELIS; NACIMENTO, 1937; MARIN et al., 2008).

A segunda é denominada de chuva orográfica que é uma variação da chuva convectiva, que é causada pela elevação de uma parcela de ar contendo vapor d'água sobre um terreno acidentado, motivo pela qual as áreas montanhosas a barlavento recebem muito mais chuva que as de sota-vento, conhecido como “sombra de chuva” (TUBELIS; NACIMENTO, 1937; MARIN et al., 2008).

Quanto a terceira forma, as chuvas frontais são formadas pelo contato de duas massas de ar relativamente homogêneas, com propriedades distintas. Massas de ar tropicais, quentes e procedentes das latitudes baixas com massas polares frias, formadas em latitudes elevadas. A colisão dá origem a uma zona de descontinuidade térmica, barométrica, e higrométrica, com variação abrupta nas propriedades atmosféricas, causando a frente fria que sempre está associada a mudanças mais ou menos bruscas das condições atmosféricas (MARIN et al., 2008).

## **2.7 Caracterizações Climatológicas da Área de Estudo**

O Oeste Paulista, ou mais especificamente o sudeste Paulista, região relacionada à área de estudo vem, ao longo do tempo, recebendo

inúmeras denominações, com diferentes extensões definidas pelos órgãos oficiais e pesquisadores que ali desenvolveram seus estudos.

Também denominada de Pontal do Paranapanema, a região em destaque, recebeu esta denominação no trabalho de Leite (1981), ao estudar a área da Grande Reserva Florestal do Pontal do Paranapanema, que compreendia municípios de Rosana, Euclides da Cunha Paulista, Teodoro Sampaio e parte dos municípios de Marabá Paulista e Presidente Epitácio (SANTOS, 2011).

Posteriormente, Passos (1991) denominou de Pontal do Paranapanema a região situada no extremo Oeste do Estado de São Paulo, na fronteira com o estado do Mato Grosso do Sul e Paraná, caracterizada pela existência de 26 municípios, sendo eles: Álvares Machado, Anhumas, Caiuá, Estrela do Norte, Euclides da Cunha Paulista, Iepê, Indiana, Marabá Paulista, Martinópolis, Mirante do Paranapanema, Nantes, Narandiba, Piquerobi, Pirapozinho, Presidente Bernardes, Presidente Epitácio, Presidente Prudente, Presidente Venceslau, Rancharia, Regente Feijó, Rosana, Sandovalina, Santo Anastácio, Taciba, Tarabai e Teodoro Sampaio.

A região de Presidente Prudente ou ainda denominada de Pontal do Paranapanema, apesar de ter grande extensão, possui algumas características climáticas que, de acordo com Monteiro (1973), é tipicamente tropical e caracterizada por período seco no inverno, sendo influenciado, predominantemente pelos sistemas polares que causam chuva durante o verão, devido à influência dos sistemas tropicais.

Essa característica é representada na classificação proposta por Monteiro (1973), que demonstra uma área de transição climática, compartilhada pelo sistema atmosférico inter e extratropical, nele ocorre conflito entre as massas Tropical Atlântica e Tropical Continental, e a massa Polar Atlântica, havendo ainda participação esporádica da massa Equatorial Continental (MONTEIRO, 1973; BOIN, 2000; FLORES, 2000).

O estudo das características da circulação atmosférica e dos sistemas atmosféricos geradores de tipos de tempo, nesta região, permite análises capazes de traçar um quadro preciso da distribuição temporal e espacial das chuvas no Oeste Paulista. De acordo com o estudo de Monteiro

(1973), representado pelos setores VIII e IX (Figura 1), e Boin (2000), esta região apresenta as seguintes características.

[...] A principal característica climática desta área do Oeste é a participação das massas de Oeste-Noroeste. Estas correntes, no inverno, provocam o aquecimento pré-frontal, responsável pela explicação das chuvas de inverno, de forma reduzida, constituindo um período seco, mas mais intensas que aquelas produzidas no centro norte. Este comportamento em relação ao Centro-Norte inverte-se na primavera e no verão, se bem que os valores de chuvas nas duas áreas sejam bem maiores nestas estações do ano [...] (BOIN, 2000, p. 23).

Segundo Monteiro (1973) e Boin (2000) o Setor VIII tem características climáticas influenciadas por massas de Oeste-Noroeste, na qual as correntes do inverno provocam o aquecimento pré-frontal, provocando as poucas chuvas de inverno, denominado como período seco. Já no Setor IX, de acordo com Monteiro (op cit), as massas de ar variam de acordo com os espigões (picos) e vales. Sendo que na feição sudeste (IX) o clima zonal é controlado por massas polares e tropicais, na qual o clima regional é de caráter úmido, dominado pela massa tropical, ou mesmo como citado por Boin (2000).

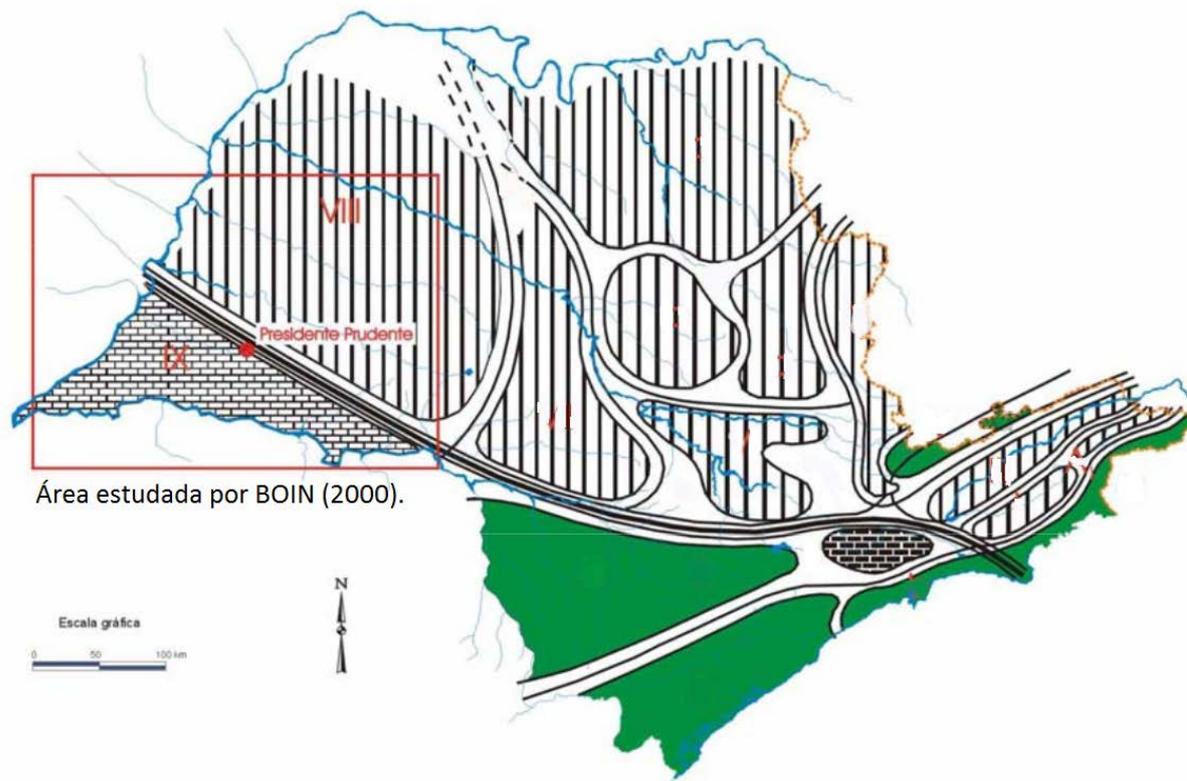
[...] No extremo sudoeste do estado, ainda sob a influência da participação das massas continentais, temos uma íntima relação com a área anterior. Sua localização, mais ao sul, o coloca, no entanto, sob maior influência das massas polares. É a maior participação das massas polares no inverno que, apesar de não eliminar o caráter seco desta estação, confere, a esta área, um maior índice de chuvas que na área a norte da faixa zonal [...] (BOIN, 2000, p. 23).

A Figura 1 demonstra de maneira fácil, á entender a área estudada por Boin (2000), marcada em vermelho. A nomenclatura VIII e IX foi proposta inicialmente por Monteiro (1973) devido à faixa zonal em que a cidade de Presidente Prudente se localiza.

Outro item interessante a se observar, é que a cidade de Presidente Prudente está localizada em uma faixa zonal muito tênue com relação ao clima dominante, ou seja, é um local que recebe influência de muitos elementos e fatores climáticos que dificultam a identificação do clima, e

a concomitante sucessão dos elementos que causam as chuvas, pois esta faixa zonal não é estática.

Figura 1: Região do Pontal do Paranapanema, setores VIII e IX estudadas por BOIN (2000).



Fonte: BOIN (2000, p. 24).

Esta região do Oeste do Estado de São Paulo atinge tal nível de detalhe, inicialmente devido às pesquisas de Monteiro (1973) e Boin (2000), sendo ainda proposto por Boin (2000) um modelo de circulação com base na pluviosidade da região destacada na Figura 2.

De acordo com os estudos de Boin (2000), a análise das cartas de isoietas e de superfícies de tendência permitiu explorar a gênese das chuvas na região do Oeste Paulista, na qual as passagens de frentes frias é o principal agente causador das chuvas (Correntes do sul), fortalecidas pela massa Polar Atlântica, com trajetos de longitudes mais orientais e úmidos, ou com percursos de longitudes mais ocidentais e secos, ganhando intensidade quando canalizados pelos principais vales dos rios existentes representado na Figura 2.

Figura 2: Trajetos preferências das massas de ar atuantes no Oeste Paulista - Período de trinta anos (1967-1996).



Fonte: Boin, 2000, p.195.

De acordo com a Figura 2, Boin (2000) retrata as massas de Ar da seguinte forma.

[...] A direção, a extensão e o entalhamento dos vales por onde avançam estas correntes do sul são de grande importância na definição do impacto pluvial, a ser gerado sobre as vertentes que a elas se opõem. Assim, o vale do rio Tibaji, maior afluente da margem esquerda do rio Paranapanema, que nasce próximo à cidade de Curitiba, capital do estado do Paraná, cuja direção de drenagem é SE-NW, é um dos agentes, na porção sul do Oeste Paulista, de sucessivos impactos pluviais, tanto relacionados às quantidades como à intensidade das chuvas, ali precipitadas. Outros rios que atingem o sul do Oeste Paulista, como o Pirapó, o das Cinzas e o próprio Paranapanema, também canalizam estes fluxos de ar, provocados pelas correntes de sul e, dependendo das direções de deslocamento e dos confrontos ocasionados com a massa Tropical Atlântica, atingem o Oeste Paulista, mais especificamente as

vertentes que se confrontam com estes fluxos de ar, causando um maior impacto pluvial [...] (BOIN, 2000, p 196).

Ainda neste mesmo contexto e representação, Boin (2000) propõe novo delineamento de nove unidades climatológicas para o Oeste Paulista representado na Figura 3, aproximando-se mais da realidade desta região. Apesar de tal figura representar o Oeste Paulista, destacou-se o foco deste trabalho naqueles setores que influenciam diretamente o clima da região de Presidente Prudente (retângulo em preto) Figura 3, sendo elas “Allm”, “Alm”, “Blllm”, “BIVm $\alpha$ ” e “BIVm $\beta$ ” (BOIN, 2000).

As nomenclaturas sugeridas aos setores da Figura 3, propostas por Boin (2000), possuem faixas zonais que separam os principais climas regionais (A ao norte e B ao sul), fundamentada no índice anual das correntes atmosféricas estabelecidos por Monteiro (1973), delimitando quatro porções em algarismos romanos (I, II, III e IV), marcando assim as áreas onde mais ocorrem determinados sistemas atmosféricos, ou seja, um trajeto específico da corrente de ar.

De acordo com Boin (2000), a letra “m” está relacionada à altitude média, pois representa uma estreita relação entre os índices pluviométricos. A letra grega “ $\alpha$ ” representa o limite da área onde chuvas da primavera costumam superar as chuvas de verão, já a letra grega “ $\beta$ ”, representa a área em que as chuvas da primavera costumam se igualar às chuvas de verão.

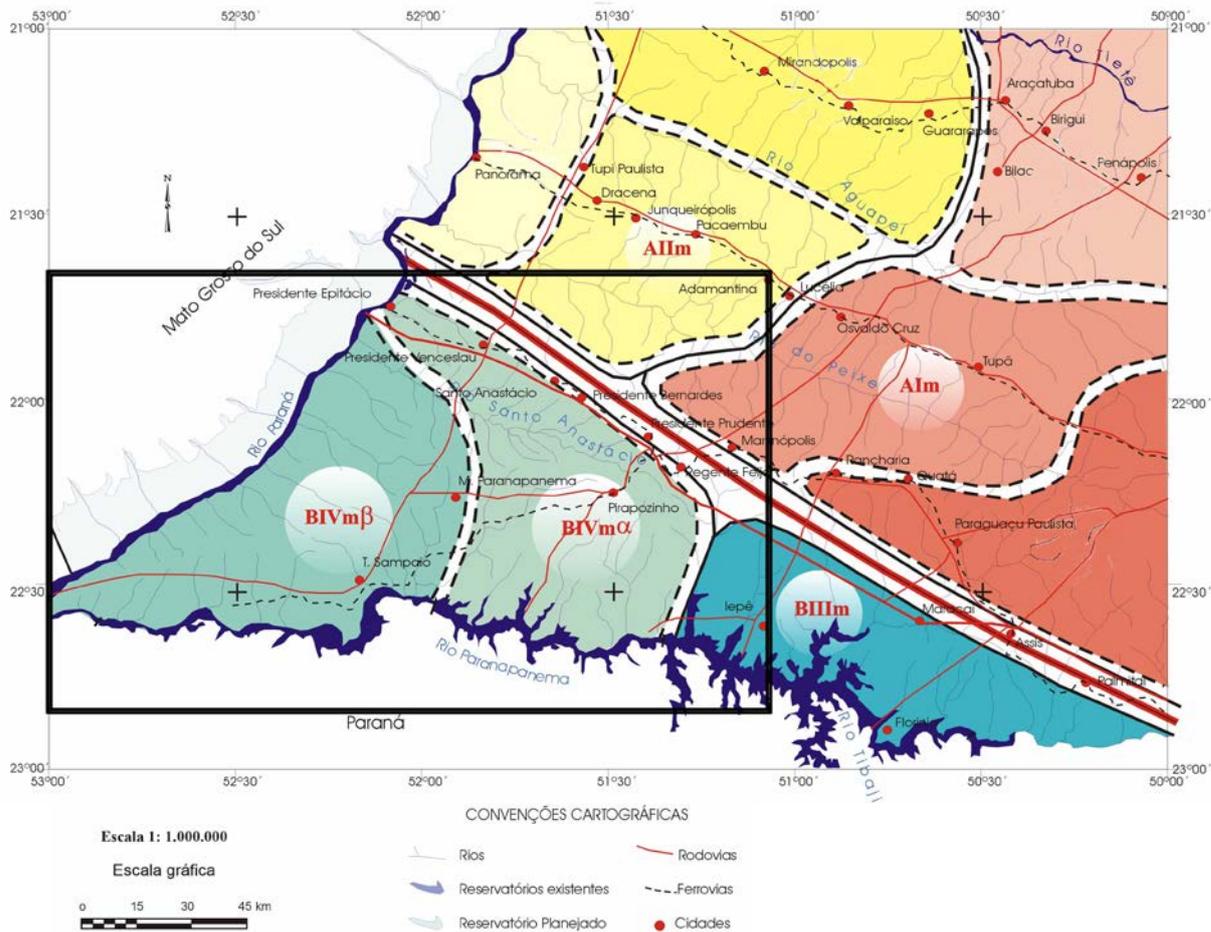
Para explicar o complexo climático da região de Presidente Prudente, deve-se considerar que a área em questão encontra-se sobre uma faixa de transição climática zonal, ainda influenciada por variações sazonais e as de relevo. Esta complexidade estabelece características pluviométricas distintas para as diferentes unidades climáticas da região (Figura 3).

Assim a unidade “Alm” (Região de Tupã, ao norte da faixa zonal), possuem índices pluviométricos menores que a porção “Allm” com características de precipitação frontal, sendo influenciada fortemente pelas frentes Polares Atlânticas. Já na porção “Allm” (Região de Dracena-Adamantina), ao norte da faixa zonal é controlada por massas equatoriais e tropicais classificando a região com tropical, alterando períodos seco e úmido, com fortes influências da massa Tropical Atlântica, com poucas atuações da massa Equatorial Continental e Tropical Continental (BOIN, 2000).

Agora, observando a porção “BIII $\mu$ ” da Figura 3 (Região de Iepê), é controlada por massas Tropicais e pela massa Polar Atlântica, sendo que a pluviosidade é provocada principalmente por chuvas frontais ou advectivas (BOIN, 2000).

Por último, ainda ao sul da faixa zonal, definem-se duas outras unidades “BIV $\mu\alpha$ ”, e “BIV $\mu\beta$ ” da Figura 3, que compreendem respectivamente, a região de Presidente Prudente “ $\alpha$ ” e Pontal do Paranapanema “ $\beta$ ”. Estas unidades são semelhantes em seu relevo e índices pluviométricos, pois estas porções são dominadas pela massa Tropical Atlântica e da Polar Atlântica, sendo que na região de Presidente Prudente “BIV $\mu\alpha$ ” a chuva é predominantemente ocasionada pela atividade frontal, e na unidade do Pontal do Paranapanema “BIV $\mu\beta$ ”, a pluviosidade fica por conta do ramo Polar Continental que se aproveita do vale do rio Paraná, atraído pela massa tropical continental (BOIN, 2000).

Figura 3: Integração de classificação de base genética e detalhamento das unidades climáticas, focando áreas que influenciam o ritmo climático da região de Presidente Prudente (Alm, Allm, BIIIIm, BIVm $\alpha$  e BIVm $\beta$ ).



Fonte: Boin, 2000 p. 203.

De acordo com as propostas realizadas por Monteiro (1971, 1973) e Boin (2000), é possível observar que a cidade de Presidente Prudente representada na Figura 3, fica em uma área de transição climática, onde atuam diferentes sistemas atmosféricos que geram dinâmica climática complexa à esta área.

Neste sentido, tanto os elementos, quanto os fatores climáticos em sua complexidade de acontecimentos, o método proposto por Monteiro (1973), e aprofundado por Boin (2000) revelam-se muito interessante, pois demonstra como o balanço da chuva acontece, determinando assim um padrão que é possível ser detectado por modelos matemáticos, como descritos nos capítulos seguintes relatados neste trabalho.

### 3 FUNDAMENTAÇÕES TEÓRICAS DA REDE NEURAL ARTIFICIAL

De acordo com a descrição de Kovács (1996), como qualquer célula biológica, o neurônio é delimitado por uma fina membrana celular que além de sua função biológica normal, possui determinadas propriedades que são essenciais para o funcionamento elétrico da célula nervosa. A partir do corpo celular, os processos metabólicos da célula nervosa projetam extensões filamentosas, conhecidas como dendritos e axônio.

A partir de estudos realizados na década de 50 e 60, passou-se a entender o neurônio biológico como sendo basicamente o dispositivo computacional elementar do sistema nervoso, que possuía múltiplas entradas e apenas uma saída. As entradas ocorrem através das conexões sinápticas, que conectam a árvore dendrital aos axônios de outras células nervosas. Os sinais que chegam por esses axônios são pulsos elétricos conhecidos como impulsos nervosos ou atividades que constituem a informação que o neurônio processará de alguma forma, para produzir como saída um impulso nervoso no seu axônio (KOVÁCS, 1996).

Como destacou Kovács (1996), no neurônio biológico, há uma integração espaço temporal dos estímulos:

“A polarização ocorre imediatamente após a chegada do impulso nervoso na árvore dendrital e se propaga por difusão passiva por toda a membrana até o local em que poderá interferir no surgimento de um potencial de ação (axônio) e, com o tempo, decai de maneira exponencial. Isto é, a membrana mantém, por algum tempo, a memória da atividade sináptica. Este fenômeno é conhecido como integração temporal dos estímulos pelo neurônio. Por outro lado, o potencial de ação é provocado no axônio de um neurônio pelo efeito combinado de todos os estímulos excitatórios e inibitórios que chegam à sua árvore dendrital. Esta característica reflete a integração espacial dos estímulos.” (KOVÁCS, 1996, p.6)

O neurônio de McCulloch é um dispositivo binário, no qual a sua saída poderia ser pulso ou não pulso, e as suas várias entradas obtêm ganhos arbitrário, podendo ser excitatórias ou inibitórias (MCCULLOCH; PITTS, 1943 apud KOVÁCS, 1996).

As entradas do neurônio correspondem ao vetor de entrada  $X = [x_1, x_2, \dots, x_n]^T$  de dimensão  $n$ . Para cada uma das entradas  $x_i$ , há um peso correspondente  $w_i$ , e a saída linear  $u$ , é dada por:

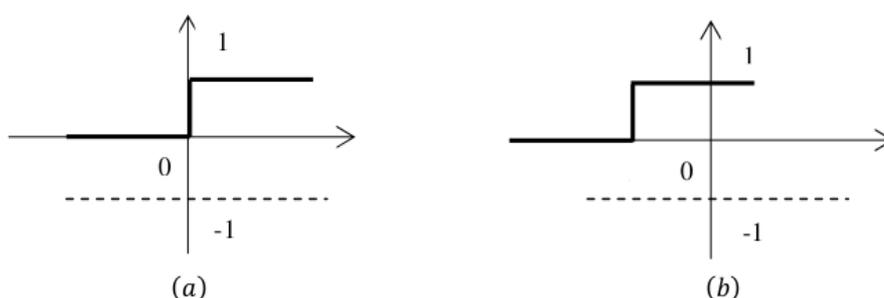
$$u = \sum w_i x_i \quad \text{Equação 1}$$

na qual Kovács (1996), denota que a saída de  $y$  do neurônio, chamada de saída de ativação, é obtida pela aplicação de uma função  $f$  à saída linear  $u$ , indicada por  $y = f(u)$ . A função  $f$  é chamada de função de ativação e pode assumir várias formas, geralmente não lineares.

Existem várias funções de ativação  $f$ , sendo que as principais são: (HAYKIN, 1994).

- **Função degrau:** A função degrau representada na Figura 4, limita a saída do neurônio a 0, se a função de propagação  $n$  for menor do que 0, ou limita a saída do neurônio a 1, se o valor da função de propagação  $n$  for maior ou igual a 0. É usada em Perceptrons para classificação de decisões.

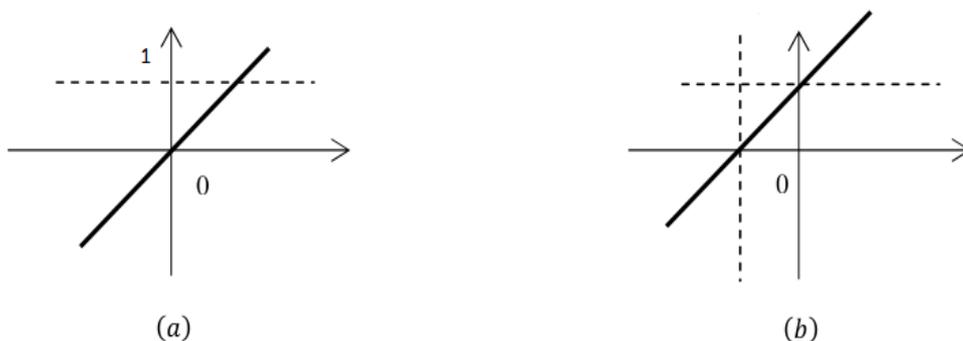
Figura 4: Representação gráfica da função de ativação do tipo degrau.



Fonte: KOVÁCS; ZSOLT (1996).

- **Função linear:** A função de ativação linear, mostrada na Figura 5, é definida pela equação  $y = \alpha x$ , onde  $\alpha$  é um número real que define a saída linear para os valores de entrada, e  $y$  é a saída e  $x$  é a entrada.

Figura 5: Representação gráfica da função de ativação do tipo Linear.



Fonte: KOVÁCS; ZSOLT (1996).

- Função sigmoide:** A função sigmóide, representada na Figura 6, é uma função estritamente crescente, que exibe um balanceamento adequado entre comportamento linear e não linear. Ela é comumente usada em redes neurais que usam o algoritmo *backpropagation*, principalmente, devido à sua suavização na saída de seus valores, que é um diferencial. A entrada da função sigmóide pode assumir qualquer valor entre menos infinito e mais infinito, que restringe a sua saída de valores entre 0 e 1.

Figura 6: Representação gráfica da função de ativação do tipo sigmóide.



Fonte: KOVÁCS; ZSOLT (1996).

Com estas funções de ativação e aprendizagem é possível modelar o Perceptron, considerando a rede neural artificial (RNA) de estrutura mais simples existente, utilizada com sucesso na classificação de padrões.

Proposto por Rosenblatt (1958, apud KOVÁCS, 1996) é o primeiro modelo bem sucedido de aprendizado supervisionado.

A rede neural Perceptron segue o modelo proposto por McCulloch e Pitts (1943, apud KOVÁCS, 1996), sendo sua topologia composta por uma camada de entrada e uma de saída contendo, em cada uma delas, um ou mais neurônios artificiais, e nenhuma camada intermediária ou escondida, observando que os neurônios da camada de entrada são apenas distribuidores, não possuindo pesos.

A proposta da criação do Perceptron foi para realizar a classificação de padrões, entretanto, como mencionando por Tafner e colaboradores (TAFNER; XEREZ; ILSON, 1996), o Perceptron não podia ser usado como solução para qualquer tipo de problema de classificação. De acordo com Haykin (1994), ficou provado que o Perceptron não resolvia problemas que apresentassem superfícies linearmente não separáveis entre as classes, como o caso do OU-exclusivo que é a porta lógica de duas entradas apresentando saída com nível lógico 1, apenas quando suas entradas diferem, ou seja, quando  $A=0$  e  $B=1$  ou  $A=1$  e  $B=0$ .

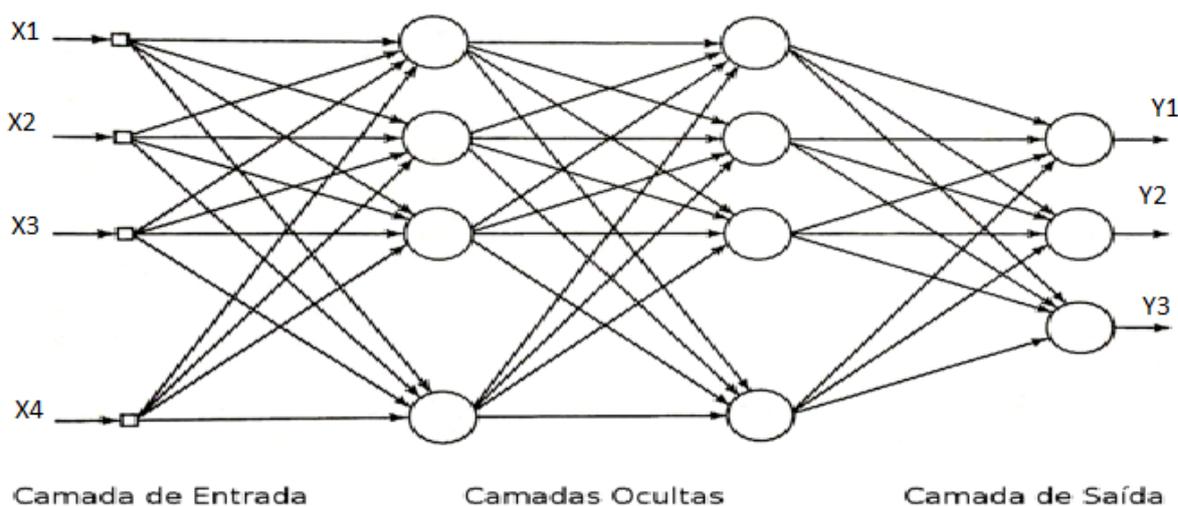
A solução apresentada para a solução do problema foi à construção de redes neurais semelhantes ao Perceptron, porém, com múltiplas camadas intermediárias ou escondidas, denominadas Perceptron de Múltiplas Camadas. No entanto, naquela época, ainda não existia um algoritmo de aprendizado capaz de treinar redes neurais com mais de uma camada de neurônios artificiais, mas com a utilização do algoritmo *backpropagation* proposto por Rumelhart, Hinton e Williams (1986, apud HAYKIN, 2001) demonstra com clareza como esse modelo poderia funcionar, no entanto, vários estudiosos propuseram no mesmo período possibilidades em construir esse modelo como, por exemplo, Bryson e Ho (1975), Baum (1988), Werbos (1990) buscando melhorar os resultados do *backpropagation* chegando a quase erradicar os erros e problemas dos cálculos.

Analisando o comportamento do neurônio representado pela Equação 1, e de acordo com Braga, Carvalho e Ludemir (2000), considerando uma entrada de dados com duas variáveis, podemos observar que a equação de decisão por meio da qual o neurônio ativa ou não a sua saída é equivalente

a  $w_1x_1 + w_2x_2 = \emptyset$ , que corresponde à equação de uma reta no espaço das variáveis de entrada  $x_1$  e  $x_2$ . Onde cada conjunto de valores diferentes de  $w_1$ ,  $w_2$  e  $\emptyset$  gera uma reta diferente no espaço de entrada, definido pelas variáveis  $x_1$  e  $x_2$ . Desta forma, entende-se melhor o aprendizado da RNA, que nada mais é do que o ajuste dos pesos  $w$  e de  $\emptyset$ , de maneira que a superfície de decisão, neste caso uma reta, atenda aos requisitos de parada de um algoritmo.

Uma Rede Neural é formada por elementos processadores simples. Cada elemento processador executa uma função simples, mas a RNA como um todo, tem capacidade computacional para resolução de problemas complexos. A estrutura apresentada na Figura 7 possui quatro entradas ( $x_1, x_2, x_3, x_4$ ), três saídas ( $y_1, y_2, y_3$ ) e quatro neurônios em cada camada intermediária, é capaz de resolver problemas de regressão, classificação ou identificação no espaço  $R^4$ . É também um exemplo de rede neural do tipo alimentada para frente (*feedforward*) (BRAGA; CARVALHO; LUDEMIR, 2000).

Figura 7: Representação simplificada da arquitetura de uma rede neural construída por duas camadas ocultas.



Fonte: HAYKIN, (2001, p.186).

As redes neurais artificiais caracterizam-se pelo aprendizado realizado através de exemplos. Para um determinado conjunto de dados, o algoritmo de aprendizado deve ser responsável pela adaptação dos parâmetros da rede, de maneira que, em um número finito de interações do algoritmo, haja convergência para uma solução. O critério de convergência varia de acordo com o algoritmo e com o paradigma de aprendizado, mas pode envolver, por exemplo, a minimização de uma função objetivo, a variação do erro de saída ou mesmo a variação das magnitudes dos vetores de peso da rede (BRAGA; CARVALHO; LUDEMIR, 2000).

Basicamente, considera-se que o processo de aprendizado tem como característica a ocorrência de estímulo da rede pelo meio externo, através da apresentação do conjunto de dados. Como consequência deste estímulo, o algoritmo de aprendizado provoca mudanças nos parâmetros da rede e, finalmente, a mudança dos parâmetros acarreta uma mudança no comportamento da RNA. Espera-se que a mudança gradual no comportamento da rede resulte em melhoria gradativa do seu desempenho. A modificação do processamento ou da estrutura de conhecimento de uma rede neural envolve a alteração do seu padrão de interconexão (KOVÁCS, 1996).

Em princípio, isto pode ser feito de três maneiras:

- Desenvolvimento de novas conexões;
- Perda de conexões existentes na rede ou;
- Modificação dos pesos das conexões já existentes.

Segundo Braga, Carvalho e Ludemir (2000), “[...] o objetivo principal do aprendizado em Redes Neurais é a obtenção de modelos com boa capacidade de generalização tendo como base o conjunto de dados [...]”. Em problemas de aproximação, classificação e identificação, o conjunto de treinamento é composto por pares de entrada e saída  $(x, y_d)$ , sendo caracterizada previamente a saída desejada  $y_d$  para um determinado valor de entrada  $x$ . O

ajuste de pesos deve modificar a saída  $\mathbf{y}$  de forma que a diferença entre  $\mathbf{y}$  e  $y_d$ , ou seja, o erro seja reduzido a cada iteração.

No entanto, a minimização do erro pode levar à resultados insatisfatórios. Desta forma, é preciso fazer mais do que simplesmente minimizar o erro do conjunto de treinamento a fim de se obter uma boa resposta de generalização. O objetivo dos algoritmos de treinamento deve ser o de aproximar as funções geradoras  $f_g$  dos dados e não simplesmente o de minimizar o erro do conjunto de treinamento.

Para esse aprendizado, podem-se empregar os seguintes métodos:

- **Aprendizado supervisionado:** neste método a rede deve ser capaz de medir a diferença entre seu comportamento atual e o comportamento de referência, e então corrigir os pesos de maneira a reduzir este erro;
- **Aprendizado não supervisionado:** os pesos da rede são modificados em função de critérios internos como, por exemplo, a repetição de padrões de ativação em paralelo de vários neurônios. O comportamento resultante deste tipo de aprendizado é usualmente comparado com técnicas de análise de dados empregadas na estatística;
- **Aprendizado por competição:** nesse caso é dado um padrão de entrada para fazer com que as unidades de saída disputem entre si para serem ativadas. Neste modelo existe uma competição entre as unidades de saída para decidir qual delas será a vencedora, e que conseqüentemente, terá a sua saída ativada e seus pesos atualizados, no treinamento;
- **Aprendizado por reforço:** esse pode ser visto como um caso particular de aprendizado supervisionado. A principal diferença

entre o supervisionado clássico e o aprendizado por reforço é a média de desempenho usada em cada um dos sistemas.

### 3.1 Caracterização da Rede *Backpropagation*

A rede *Backpropagation* de Múltiplas Camadas (MLP) é uma generalização da rede Perceptron, proposta por Rosenblatt (1958, apud KOVÁCS, 1996), onde cada neurônio da camada antecedente se conecta com todos os neurônios artificiais da camada seguinte, e assim por diante. A rede é treinada de forma supervisionada, usando o algoritmo da *backpropagation* do erro fundamentado na regra delta ADALINE generalizada, que ajusta os pesos sinápticos através de estimativas do vetor do erro em relação aos pesos sinápticos.

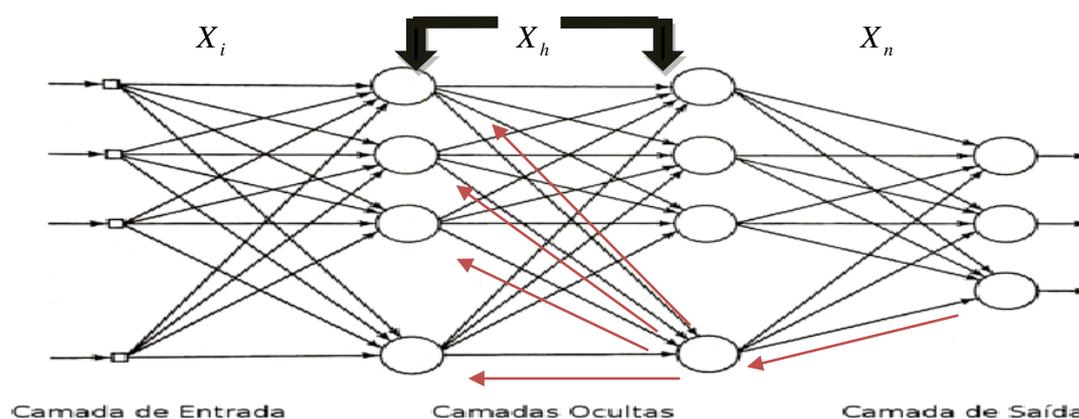
O elemento que usa a regra Delta de WIDROW, é chamado de ADALINE (Adaptative Linear Neuron ou Adaptative Linear Element) (BRAGA; CARVALHO; LUDEMIR, 2000). A taxa de aprendizado  $n$  mede o passo a ser adotado pela rede em busca da convergência e mínimo global. Se a taxa  $n$  for pequena a convergência se torna muito lenta, podendo até paralisar o treinamento. Caso contrário, se a taxa de  $n$  for muito elevada, o treinamento pode não atingir a resposta desejada.

A rede possui uma topologia com uma camada sensorial ou de entrada, que possui a quantidade de nós de entrada na mesma proporção dos sinais de entrada, que dependem intrinsecamente do problema, uma ou mais camadas intermediárias ou ocultas de neurônios e uma camada de saída com um número de neurônios idênticos ao número de sinais de saída, que são tantos quantos forem necessários para a modelagem do problema. O sinal de entrada se propaga para frente (feedforward) através das camadas ocultas, até a camada de saída. Portanto, a MLP é uma rede alimentada para frente.

O número de camadas ocultas e a quantidade de neurônios artificiais, de cada uma dessas camadas, dependem da complexidade do problema que se deseja solucionar. A Figura 8 mostra a arquitetura de um MLP, onde  $X_i$ ,  $X_h$  e  $X_n$  correspondem, respectivamente, ao número de elementos dos vetores da camada de entrada, da camada oculta e da camada de saída.

A seguir, os elementos,  $X_i$ ,  $X_h$  e  $X_n$  correspondem, respectivamente, aos vetores dos sinais de entrada, camada oculta da RNA, e das saídas desejadas impostas pelo “supervisor”.

Figura 8: Representação de uma rede neural Multicamada Perceptron.



Fonte: BRAGA; CARVALHO; LUDEMIR, (2000).

O treinamento da MLP, usando o algoritmo *backpropagation* (BP) é realizado em duas etapas: a primeira é chamada de propagação e a segunda de retro propagação (ARTERO, 2009). Durante a primeira etapa do treinamento o vetor de sinais de entrada  $X_i = [X_1, X_2, X_3, X_4, \dots, X_n]^T$  é aplicado a cada neurônio da primeira camada oculta da rede, cada qual calculando a sua respectiva saída, que é transmitida para frente como sinal de entrada para todos os neurônios da camada oculta subsequente  $X_h$ . O mesmo procedimento de cálculo e transmissão é repetido, até a camada de saída da rede, quando o valor da saída obtida pela rede  $X_n = [X_1, X_2, \dots, X_n]^T$ , é comparado com o valor da saída desejada  $S$  (saída), obtendo-se o sinal de erro  $e_j = T_j - S_j$  de cada neurônio  $j$  desta camada para cada padrão apresentado.

O erro entre a saída da rede e o desejado, considerado por todos os  $X_n$  neurônios da camada de saída  $j$  e após a apresentação de todos os padrões de treinamento, completando assim um período, é calculado e definido por

$$E = \frac{1}{Q} \sum_{q=1}^Q E^q = \frac{1}{Q} \sum_{q=1}^Q \cdot \frac{1}{2} \sum_{j=1}^{N_o} (e_j)^2 = \frac{1}{Q} \sum_{q=1}^Q \cdot \frac{1}{2} \sum_{j=1}^{N_o} (T_j - O_j)^2 \quad \text{Equação 2}$$

onde  $O_j$  e  $T_j$  são respectivamente a saída calculada e a saída desejada para o neurônio  $j$ , onde  $j = 1, 2, \dots, N_o$  e  $E^q$  é o erro total instantâneo no padrão  $q$  (KOVÁCS, 1996).

A segunda etapa ocorre em sentido contrário, há uma retropropagação do sinal de erro calculando-se  $\delta$  de cada neurônio, atualizando os pesos das conexões a partir da camada de saída  $j$ , propagando-se recursivamente pelas camadas ocultas até a camada de entrada, pelo uso da regra delta generalizada representada pela Equação 3:

$$\Delta W_{ji} = -N \cdot \frac{(\partial E)}{(\partial W_{ji})} \quad \text{Equação 3}$$

onde  $N$  é a taxa de aprendizado e  $i$  indica indexação referente à camada anterior  $l$ .

Verifica-se na Equação 3 que o algoritmo BP, calcula as derivadas parciais de uma função de erro  $E$ , com relação ao vetor peso  $W$ , de certo vetor de entrada  $X$ . O algoritmo BP, apesar de eficiente em várias aplicações pode demorar a convergir.

A taxa de aprendizado  $N$  responde à velocidade com que ocorre a busca no espaço dos pesos, em direção aos valores que resultam em um erro global mínimo. Se a taxa de aprendizado não for adequadamente escolhida, podem ocorrer problemas durante o treinamento da rede. Quanto menor o valor de  $N$  mais suave será a curva de treinamento, porém o aprendizado se tornará muito lento, podendo inclusive, ocorrer uma paralisia da rede em pontos onde a derivada da função de ativação seja nula ou infinitamente pequena.

O treinamento onde a taxa de aprendizado é muito baixa, com uma variação muito pequena de  $\Delta W_{ji}$  de um cálculo para outro, provoca uma suave trajetória no espaço dos pesos, aumentando as chances de a rede ficar presa em um mínimo local, ou, na melhor das hipóteses, o treinamento ficar

muito lento. Em contrapartida, se for usado um valor muito alto para a taxa de aprendizado, ocorrerão modificações muito intensas nos pesos, devido a uma alta variação de  $\Delta W_{ji}$ , provocando oscilações intensas na curva de treinamento e instabilidade na rede.

O problema da ocorrência de oscilações na curva de treinamento da RNA devido á utilização de altas taxas de aprendizado pode ser bastante amenizado através do uso de Coeficiente de Momento (*momentum*) na regra delta, de acordo com (BRAGA; CARVALHO; LUDEMIR, 2000). Desta forma, o termo *momentum* passa a ser representado pela seguinte função:

$$W_{ji}(T+1) = W_{ji} + N\sigma_j(t)x_i(t) + \alpha(W_{ij}(t) - W_{ij}(T-1)) \quad \text{Equação 4}$$

Ao se utilizar da Equação 4, caracterizado por momentum, segundo Braga, Carvalho e Ludemir (2000), haverá um aumento na velocidade de aprendizado e redução na instabilidade, ou seja, suprime a oscilação de pesos apontando possíveis novos valores como sendo os melhores no aprendizado.

### 3.2 Fundamentações da Máquina de Vetor de Suporte

As Máquinas de Vetores de Suporte (SVM) constituem uma das técnicas de aprendizado de máquinas de maior flexibilidade. Têm apresentado resultados equivalentes e, muitas vezes, superiores aos alcançados por outros algoritmos de aprendizado, inclusive outros tipos de RNAs (BRAGA; CARVALHO; LUDEMIR, 2000).

As SVM são Redes Neurais do tipo *feedforward*, que possuem camadas escondidas com neurônios não lineares, sendo um método de aprendizado de máquinas elegante e altamente fundamentado por Haykin (2001). As SVM têm forte embasamento conceitual proveniente da Teoria do Aprendizado Estatístico, que orienta a busca pela melhor solução para um dado problema de aprendizado. Esta busca é realizada através da minimização não só do erro de treinamento, mas também da complexidade do modelo obtido, o que resulta em um dos principais pontos fortes das SVM's, que é a

alta capacidade de generalização. A extração dos vetores de suporte, principais padrões de treinamento responsáveis pela definição da solução do problema de aprendizado é outro ponto de destaque das SVM (SCHÖLKOPF; DECOSTE, 2002).

De acordo com Chapelle et al. (2002), a teoria do aprendizado estatístico tenta a maximização da capacidade de generalização de uma RNA, apresentando uma formulação matemática para o controle da capacidade de generalização de uma máquina de aprendizado genérico.

Outro item importante no estudo de máquinas de vetores de suporte é o da Dimensão Vapnik-Chervonenkis (VC) (VAPNIK; HERVONENKIS, 1971, apud HAYIN, 2001). A dimensão VC é uma medida da capacidade de separação de uma família de funções classificadoras, arquitetada por uma máquina de aprendizado (VAPNIK; HERVONENKIS, 1971, VAPNIK, 1999).

Dois conceitos são importantes para a definição da dimensão VC (KULKARNI; HARMAN, 2011):

- **Dicotomia** - Dizemos que as funções de classificações binárias, ou seja, aquelas que dividem o espaço em dois conjuntos disjuntos, implementam uma dicotomia;

- **Fragmentação** - Uma máquina de aprendizado tem a capacidade de construir certo número de dicotomias. Dado um conjunto  $\mathcal{S}$  de pontos, dizemos que a máquina de aprendizado fragmenta o conjunto  $\mathcal{S}$  se todas as dicotomias possíveis desse conjunto podem ser implementadas por tal máquina.

Com isso, o  $|\mathcal{S}|$  é a cardinalidade de  $\mathcal{S}$ , tem-se que o número  $N$  de dicotomias programáveis pela máquina ser igual a  $2^{|\mathcal{S}|}$ , para que tal máquina fragmente o conjunto  $\mathcal{S}$  (KULKARNI; HARMAN, 2011).

Assim, expressa Haykin (2001), “A dimensão VC de um conjunto de dicotomias  $\mathcal{S}$  é a cardinalidade do maior conjunto  $\mathcal{E}$  particionado por  $\mathcal{S}$ ”. Dito de outra forma, a dimensão VC de uma máquina de aprendizado é o maior

número de padrões de treinamento que esta pode aprender com erro zero para todas as possíveis classificações binárias destes padrões.

### 3.2.1 Hiperplano ótimo linearmente separável

Para um conjunto de dados de treinamento com padrões linearmente não separáveis, um hiperplano de separação não pode ser construído sem que erros de classificação ocorram. Para minimizar tais erros, uma superfície de decisão mais complexa precisa ser adotada, desta forma, para melhorar a separação dos dados durante o cálculo, são mapeados novos espaços de alta dimensionalidade denominados espaços de características, tais espaços de características são separados por uma margem ilusória entre os pontos da massa de dados, que pode melhorar o hiperplano utilizando a SVM linear (HAYKIN, 2001).

Basicamente, esta ideia depende de duas operações matemáticas:

1. O mapeamento não linear de um vetor de entrada para o espaço de características de alta dimensionalidade, que é oculto da entrada e da saída.
2. A construção de um hiperplano ótimo para separar as características descobertas na operação um (1).

A primeira é realizada de acordo com o teorema de Vapnik (1971) sobre a convergência uniforme, considerando-se o espaço de entrada constituído de padrões não linearmente separáveis. O teorema afirma que este espaço pode ser transformado em um novo espaço de características onde os padrões são linearmente separáveis, desde que a transformação seja não linear e a dimensionalidade do novo espaço seja suficientemente alta.

A segunda explora a ideia de se construir um hiperplano de separação ótimo, de acordo com a teoria descrita anteriormente, porém, agora definido como uma função linear de vetores retirados do espaço de características.

Segundo Haykin (2001) e Sasaki (2014), deseja-se encontrar um hiperplano ótimo que minimize a probabilidade de erro de classificação,

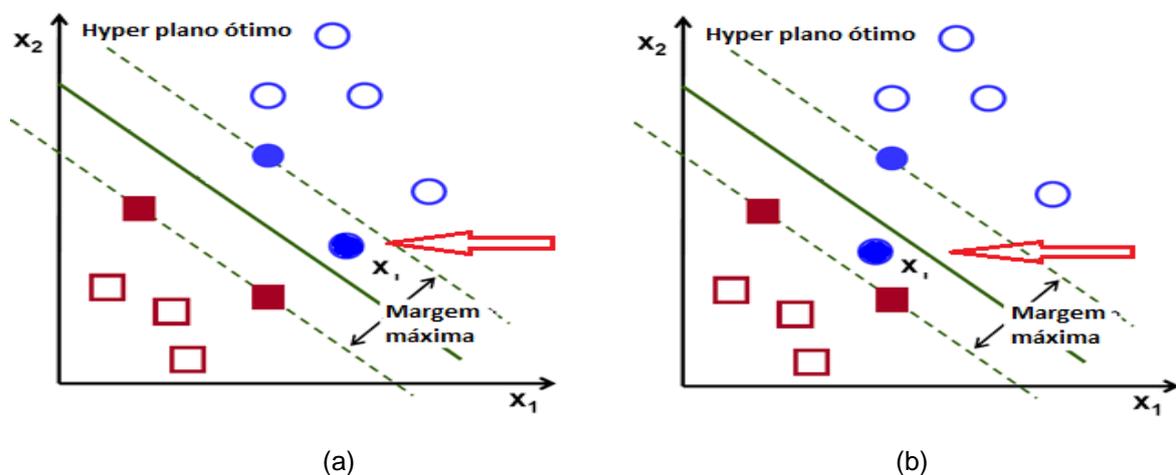
calculada como a média sobre o conjunto de treinamento. Desta forma, a margem de separação entre as classes é suave, se um ponto de dado  $(x_i, d_i)$  violar a seguinte condição:  $d_i(W^T x_i + b) \geq +1$ ,  $i = 1, 2, \dots, N$ .

Tal violação pode surgir de duas formas:

a) O ponto de dados  $(x_i, d_i)$  se encontra dentro da região de separação, mas do lado correto da superfície de decisão, como ilustrado na Figura 9(a):

b) O ponto de dados  $(x_i, d_i)$  se encontra no lado errado da superfície de decisão como ilustrado na Figura 9(b).

Figura 9: Representação gráfica do hiperplano linearmente não separável.



Fonte: HAYKIN, 2001 p.358.

De acordo com Haykin (2001) e Sasaki (2014), é possível observar uma classificação correta na Figura 9 (a), mas uma classificação incorreta na Figura 9 (b), sendo que para melhorar os pontos não separáveis, é introduzido um novo conjunto de variáveis escalares não negativas,  $\{\xi_i\}_{i=0}^N$ , na definição de separação (superfície de decisão).

$$d_i(W^T X_i + b) \geq 1 - \xi_i, \quad i = 1, 2, \dots, N \quad \text{Equação 5}$$

$\xi_i$  são variáveis soltas, e mensura o desvio de um ponto dado da condição ideal de separação de padrões. Para  $0 \leq \xi_i \leq 1$ , o ponto de dado se encontra dentro da região de separação, mas no lado correto da superfície de decisão, como ilustrado na Figura 9 (a). Para  $\xi_i > 1$ , o ponto se encontra no lado incorreto do hiperplano de separação, ilustrado na Figura 9 (b). Os vetores de suporte são aqueles pontos indicados na Figura 9 e que satisfazem precisamente a Equação 5, mesmo quando  $\xi_i > 0$ . Observa-se que, se  $\xi_i > 0$  for deixado de fora do conjunto de treinamento, a superfície de decisão não muda, sendo assim, os vetores de suporte são definidos exatamente do mesmo modo tanto para o caso linearmente separável como para o caso não separável.

Em todas as equações de treinamento, torna-se comum empregar a função Núcleo sem conhecer o mapeamento entre os espaços, que é gerado implicitamente. A utilidade dos núcleos está, portanto, na simplicidade do cálculo e em sua capacidade de representar espaços abstratos de alta dimensionalidade. Para garantir a convexidade do problema de otimização, além do núcleo representar mapeamentos nos quais seja possível o cálculo de produtos escalares, eles devem obedecer as condições estabelecidas pelo teorema de Mercer (MERCER, 1909 apud HAYKIN, 2001). De forma simplificada, um núcleo que satisfaz as condições de Mercer é caracterizado por dar origem a matrizes positivas semi definidas  $K$ , em que cada elemento  $K_{ij}$  é definido por  $K_{ij} = K(x_i, x_j)$ , para todo  $i, j = 1, \dots, n$  (HAYKIN, 2001).

Alguns dos Núcleos mais utilizados são os Polinomiais, Funções de Base Radial (RBF) e os Sigmoidais. Cada um deles apresenta parâmetros que devem ser determinados pelo usuário. O Núcleo Sigmoidal, em particular, satisfaz as condições de Mercer apenas para alguns valores de  $\beta_0$  e  $\beta_1$ . Os Núcleos Polinomiais com  $p=1$  também são denominados lineares. A Tabela 1 mostra estas funções e os parâmetros determinados a priori pelo usuário.

Tabela 1: Tipos de funções usadas na máquina de vetor de suporte.

Tipo de núcleo	Núcleo de produto interno $K(x, x_i), i = 1, 2, \dots, N$	Comentários
Polinomial	$(x^T x_i + 1)^p$	A potência $p$ é especificada a priori pelo usuário.
Gaussiano(RBF)	$\exp\left(-\frac{1}{2\sigma^2} \ x - x_i\ ^2\right)$	A largura $\sigma^2$ , comum a todos os núcleos, é especificada pelo usuário.
Sigmoidal	$\tanh(\beta_0 x^T x_i + \beta_1)$	O teorema de Mercer é satisfeito apenas para alguns valores de $\beta_0, \beta_1$

Fonte: HAYKIN (2001, p.366).

Para todos os três tipos de núcleos utilizados na máquina de vetor de suporte, a dimensionalidade do espaço de características é determinada pelo número de vetores de suporte, extraídos dos dados de treinamento, para solução do problema especificado. Desta forma a teoria fundamental da máquina de vetor de suporte evita a heurística frequentemente utilizada em redes de função de base radial e perceptron de múltiplas camadas convencionais.

### 3.3 Avaliação das redes neurais artificiais classificadoras

Para avaliar as classificações realizadas pelas redes neurais artificiais, é utilizada a matriz de confusão que determina a medida de qualidade de classificação que são calculadas, ou seja, a partir de uma matriz de confusão que, armazena os valores que foram classificados corretamente para cada classe.

A classificação binária que possui apenas duas classes, a matriz de confusão é composta por falso positivo (FP), falso negativo (FN), verdadeiro positivo (VP) e verdadeiro negativo (VN). Assim esse conceito é descrito da seguinte forma:

- i) Falso positivo (FP), valores preditos como pertencentes à classe positiva, mas pertencem à classe negativa;

- ii) Falso negativo (FN), valores preditos como pertencente à classe negativa, mas pertencem à classe positiva;
- iii) Verdadeiro positivo (VP), valores preditos corretamente, pertencentes à classe positiva;
- iv) Verdadeiro negativo (VN), valores preditos corretamente preditos, pertencentes à classe negativa.

Tabela 2: Representação do Verdadeiro Positivo, Verdadeiro Negativo, Falso Positivo e Falso Negativo.

	Chove	Não Chove
Positivo	VP	FP
Negativo	FN	VN

Fonte: O Autor.

A medida empírica mais utilizada, segundo Liu; Yin e Zhang (2012), é a taxa de acerto (TA), também conhecida como acurácia. Essa medida avalia quão efetivo um algoritmo é, por meio da probabilidade do algoritmo realizar predições corretas. Na equação a seguir, é mostrada a fórmula para o cálculo da acurácia.

$$TA = \frac{|VN| + |VP|}{|FN| + |FP| + |VN| + |VP|} \quad \text{Equação 6}$$

A medida complementar à acurácia é a taxa de erro (TE), que mensura a probabilidade do modelo matemático realizar falsas predições, como pode ser observado na equação a seguir.

$$TE = \frac{|FN| + |FP|}{|FN| + |FP| + |VN| + |VP|} \quad \text{Equação 7}$$

De acordo com Pessoa et al. (2012), a sensibilidade (S) e especificidade (E), avaliam a efetividade do modelo matemático para uma classe única. O cálculo da sensibilidade, também conhecida como reavaliação (recall) ou taxa de (VP), que estima a probabilidade de um valor pertencente à classe positiva ser predito como positivo, enquanto que o cálculo da especificidade estima a probabilidade de um valor pertencente à classe negativa ser predito corretamente como negativo.

A taxa de FP estima a probabilidade de um valor pertencente à classe negativa ser predito como positivo. As fórmulas de sensibilidade (VP), especificidade (VN) e taxa de FP são das pelas equações a seguir.

$$\text{Verdadeiro\_Positivo} = S = \frac{|VP|}{|VP| + |FN|} \quad \text{Equação 8}$$

$$\text{Verdadeiro\_Negativo} = S = \frac{VN}{VN + FP} \quad \text{Equação 9}$$

$$\text{Falso\_Positivo} = \frac{FP}{VN + FP} \quad \text{Equação 10}$$

A precisão (P) é a medida que estima a probabilidade da predição positiva estar correta. A fórmula da precisão é dada pela equação a seguir.

$$P = \frac{|VP|}{|VP| + |FP|} \quad \text{Equação 11}$$

Com estas fórmulas, que é possível entender através da matriz de confusão, os relatos realizados por Scott (1992), Liu; Yin e Zhang (2012), desta forma é possível ter uma melhor avaliação, conseguindo separar e quantificar exatamente quais os valores foram corretamente avaliados pela rede neural artificial e quais valores foram classificados erroneamente, além de isolar cada valor e quantificar seu real potencial de probabilidade como resultado.

#### 4 MATERIAIS E PROCEDIMENTOS METODOLÓGICOS

Inicialmente, foram coletados os dados referentes às seguintes variáveis no site do Centro de Previsão de Tempo de Estudos Climáticos (CPTEC), para o período de 1996 a 2012 (<http://bancodedados.cptec.inpe.br/downloadBDM>). Estes dados pertencem à estação meteorológica de número 83716 localizada na latitude -22.12, longitude -51.38, referentes à cidade de Presidente Prudente.

- i) Característica da variação da pressão nas últimas 3 horas;
- ii) Tipo da nuvem alta;
- iii) Tipo da nuvem baixa;
- iv) Tipo da nuvem média;
- v) Direção do vento de 0 a 360 graus;
- vi) Velocidade do vento em m/s;
- vii) Altura da base das nuvens na primeira camada em metros;
- viii) Cobertura das nuvens em %;
- ix) Cobertura das nuvens na primeira camada em oitavos;
- x) Pressão reduzida ao nível médio do mar em hPa;
- xi) Pressão ao nível da estação local em hPa;
- xii) Temperatura do ar °C;
- xiii) Ponto de orvalho °C;
- xiv) Temperatura mínima °C;
- xv) Período da precipitação acumulada em horas;
- xvi) Temperatura máxima °C;
- xvii) Umidade relativa do ar %;
- xviii) Visibilidade horizontal em metros;
- xix) Variação da pressão nas últimas 3 horas em hPa;
- xx) Tempo presente;
- xxi) Tempo passado1;
- xxii) Tempo passado2 e
- xxiii) Precipitação acumulada em mm (Classificação).

A última variável ainda que citada, é tomada como elemento de classificação, desta forma, as variáveis relacionadas ao clima são

denominadas de variáveis de entrada da RNA, sendo que existem as variáveis internas de parâmetros de cada modelo matemático, na qual são alteradas para encontrar os melhores ajustes da RNA e, conseqüentemente, obter o melhor resultado na identificação da chuva.

Ao todo, foram coletadas 14.670 linhas de informações, referentes às variáveis citadas anteriormente, sendo que a estação realiza quatro coletas de dados durante o dia: às 9:00, 15:00, 18:00 e 21:00 horas. É observado na Tabela 3 que há uma discrepância no total de linhas ou informações relacionadas a cada ano, isso ocorre devido à falha humana ou mesmo à falha nos equipamentos, no momento da coleta dos dados.

Tabela 3: Número de observações (dados) coletadas por ano, no período de 1996 à 2012.

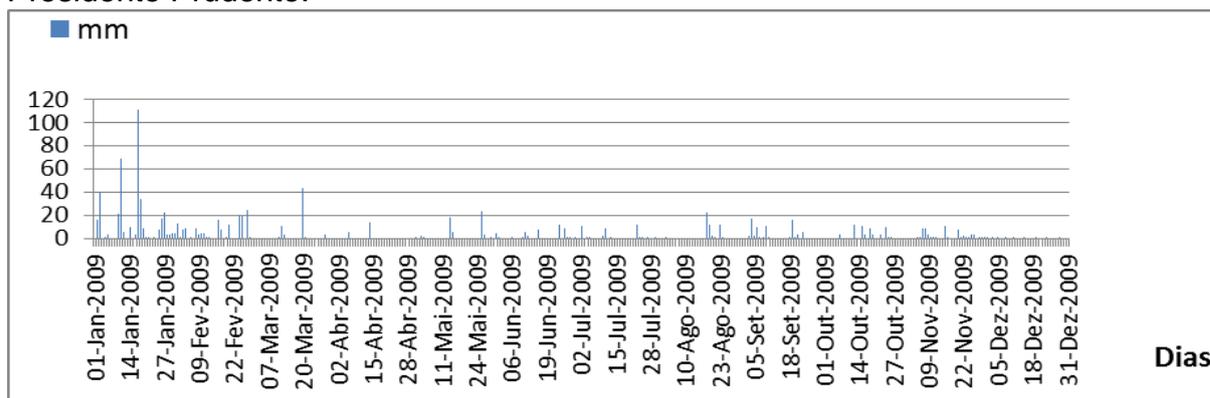
Ano	Total de observações coletadas no ano	Ano	Total de observações coletadas no ano	Ano	Total de observações coletadas no ano
1996	737	2002	832	2008	1065
1997	847	2003	757	2009	1111
1998	996	2004	634	2010	584
1999	1381	2005	509	2011	521
2000	1268	2006	1069	2012	205
2001	1069	2007	1085		

Fonte: O Autor.

Além da não continuidade dos dados relatados na Tabela 3, há outros itens desconectados, que estão relacionados ao balanço e a variabilidade da chuva, demonstrando assim a grande dificuldade de se obter dados contínuos e identificação dos padrões pluviométricos nessa região, ou seja, quando ocorre a chuva.

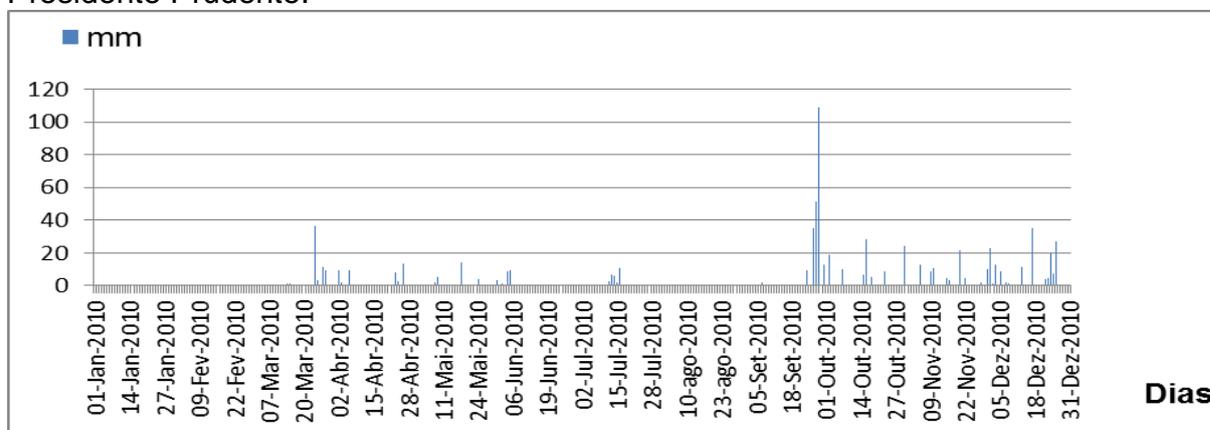
Para demonstrar a variabilidade pluvial que ocorre na cidade de Presidente Prudente, foram construídos gráficos com dados de chuva diária, obtidos a partir da Estação Meteorológica da UNESP de Presidente Prudente, dos anos de 2009, 2010 e 2011. Estes gráficos estão apresentados nas Figuras 10, 11 e 12.

Figura 10: Representação da chuva diária durante o ano 2009 na cidade de Presidente Prudente.



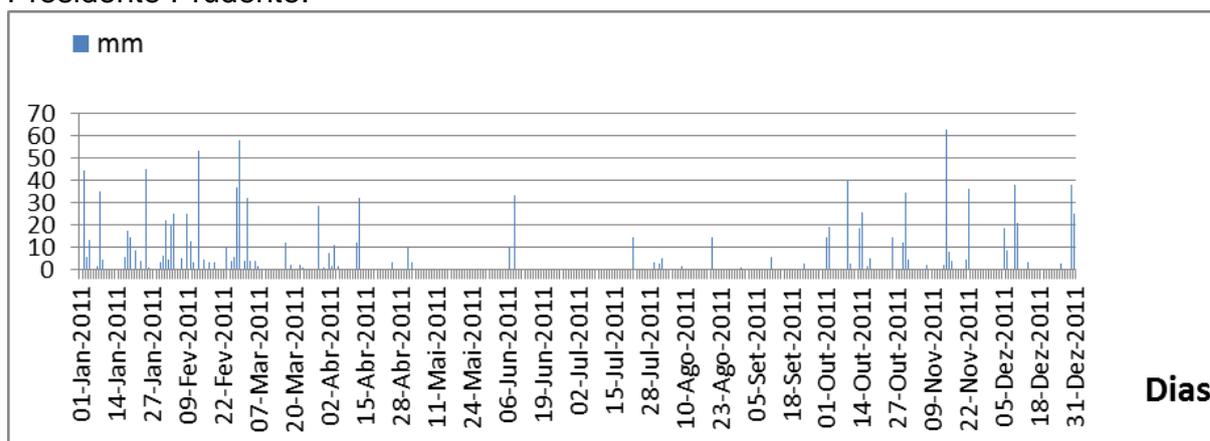
Fonte: Estação Metereológica da UNESP.

Figura 11: Representação da chuva diária durante o ano 2010 na cidade de Presidente Prudente.



Fonte: : Estação Metereológica da UNESP.

Figura 12: Representação da chuva diária durante o ano 2011 na cidade de Presidente Prudente.



Fonte: Estação Metereológica da UNESP.

\* Dados fornecidos pela Estação Metereológica da UNESP.

As Figuras 10, 11 e 12 juntas representam 1095 dias, sendo que cada figura contém 365 dias (um ano cada). Na Figura 10, é possível observar a precipitação do período de Janeiro à Março do ano de 2009, caracterizada como sendo um período normal de chuvas. Nos outros meses do ano há precipitações bem distribuídas, entretanto sem grande expressão nos meses da primavera, quando era de se esperar uma pluviosidade mais significativa, que representa um clima atípico para a região.

A Figura 11 apresenta a precipitação ocorrida no ano de 2010. Durante os meses de Janeiro à Março, observa-se que praticamente não ocorreu nenhuma pluviosidade. De Abril à Junho ocorre um aumento considerável das chuvas, incluindo alguns dias do mês de Julho que também chove. Entretanto, de acordo com Monteiro (1973), Boin e Zavattini (2000) esses meses representam um período seco. No restante do ano a precipitação ocorre em seu ciclo considerado normal para a região.

A Figura 12, que apresenta a precipitação para o ano de 2011, a distribuição dos dias de chuvas ocorre de forma condizente com o padrão normal da região e durante o ano todo apresenta certa regularidade. Durante os meses de Janeiro à Março são esperadas chuvas, de Abril à Setembro espera-se uma queda nos índices de pluviosidade, pois é considerado um período seco, e no final do ano as chuvas voltam a cair com certa intensidade.

De acordo com essa variabilidade da precipitação, sejam com relação aos meses, as estações e ainda nos anos demonstrados, a detecção, identificação e entendimento da dinâmica pluvial e seu ritmo, em busca da precipitação, são estudos complexos e de difíceis compreensões. Desta forma, para se chegar a um índice de acerto considerável na identificação da precipitação para a cidade de Presidente Prudente, este trabalho utilizou-se da interdisciplinaridade entre os conhecimentos das ciências meteorológicas, geográfica e a matemática.

Neste estudo não foram seguidas as indicações recomendadas da OMM para coletar informações de 30 anos, justamente por motivos relatados anteriormente nas Figuras 10, 11 e 12, além da falta de dados contínuos e a dificuldade em se encontrar um padrão nos balanços climáticos da região de Presidente Prudente, citados no Capítulo 2.

Os dados coletados sofreram um pré-tratamento para adentrar em conformidade e adequar-se aos parâmetros da modelagem em RNA. Este pré-tratamento foi realizado da seguinte forma:

Passo 1 – O conjunto de dados da Tabela 2 possui a seguinte estrutura: dia 1 com 0 a 4 informações meteorológicas relacionados ao dia, desta forma, dentro dessas 5 leituras, separou-se o maior valor referente ao dia de cada leitura.

Passo 2 – A RNA foi treinada para classificar os dias com chuva ou sem chuva, desta forma, os valores de precipitação tiveram que ser transformados. Até 0,95 mm classificou-se em “não chuva” e acima deste valor em “chuva”

Passo 3 – Todas as vírgulas (,) de valores decimais foram substituídas por ponto (.).

Passo 4 – Todos os valores preenchidos ambigualmente pela estação ou mesmo pelo CPTEC foram retirados.

Passo 5 – Todos os valores foram previamente normalizados com a equação  $(z_i^k)_N = \frac{z_i^k - z_{min}^k}{z_{max}^k - z_{min}^k}$ , na qual 1 é o máximo e 0 corresponde ao valor mínimo, para não ocasionar tendências nos cálculos da rede e resultados, além de evitar sobreposição de dimensões e evitar que o aprendizado fique estagnado.

Passo 6 – Foram criados aleatoriamente três conjuntos de treinamento, com 70% do total de dias, e os respectivos conjuntos de teste, com os 30% dos dados restantes. Neste caso houve a possibilidade de repetições das linhas entre os três arquivos.

Após a preparação dos dados, os arquivos contendo 70% dos dados, ou seja, os conjuntos de treinamentos foram inseridos na rede neural, para efetuar o aprendizado da mesma. Em seguida, o conjunto de teste contendo os 30% dos dados remanescentes, foram inseridos para validação do modelo gerado.

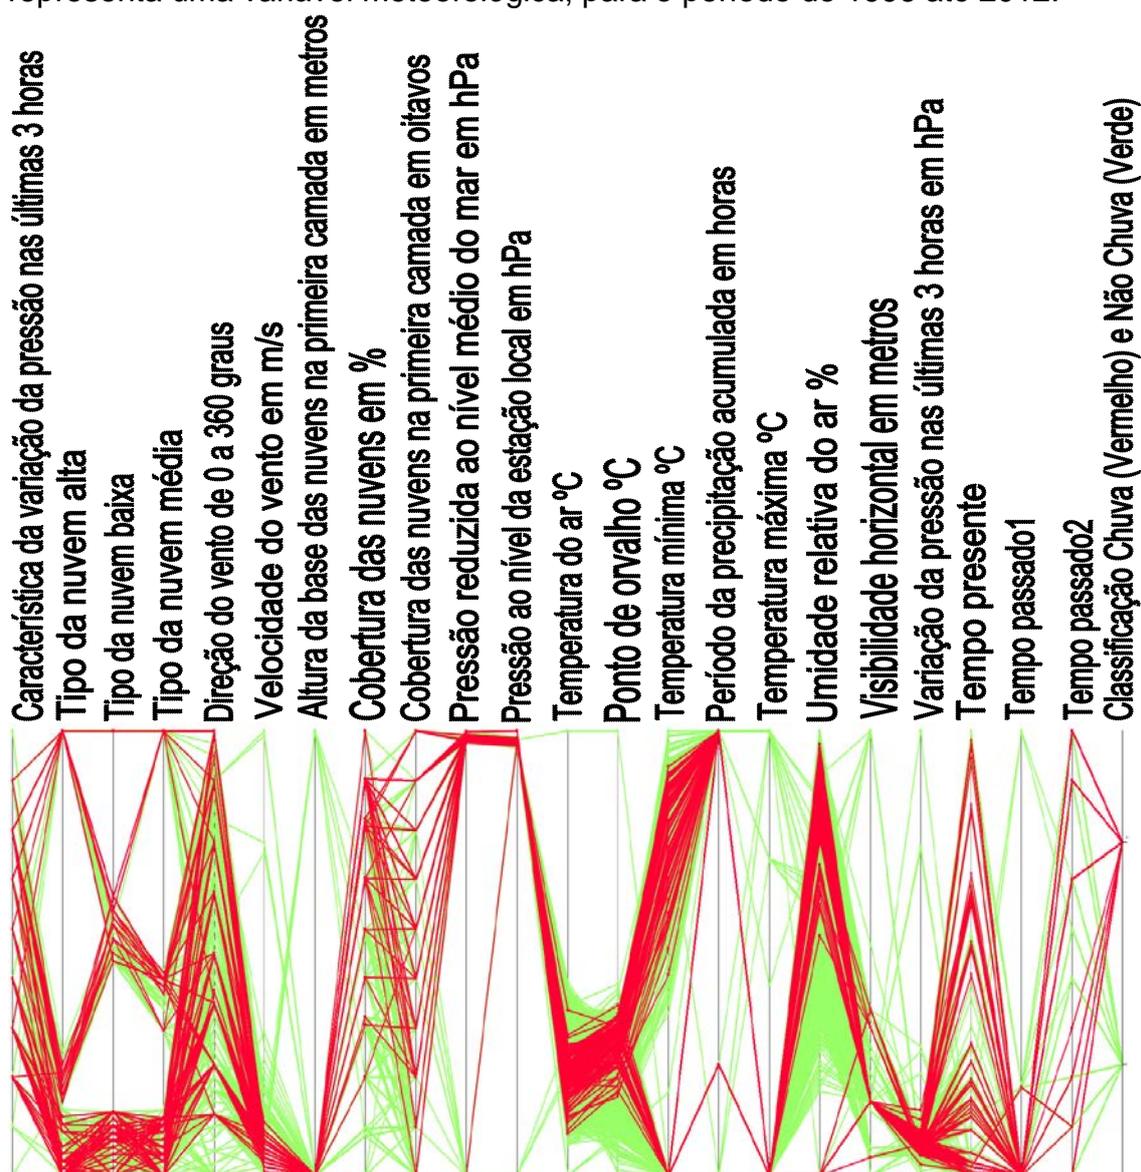
Adotou-se a metodologia do ritmo climatológico desenvolvido por Monteiro (1991) e aprofundado por Boin (2000), possibilitando qualitativamente a identificação da variabilidade que ocorre na distribuição de precipitação,

levando-se em consideração os dados coletados no período entre 1996-2012, do Centro de Previsão de Tempo e Estudos Climáticos (CPTEC).

A Figura 13 demonstra o comportamento dos valores de todos os 22 parâmetros (linhas verticais) utilizados na entrada da RNA. A cor verde caracteriza “não chuva” e a cor vermelha caracteriza “chuva”. Nesta figura observa-se um complexo emaranhado de linhas, sem ter a possibilidade de separar as linhas indicando não chuva (verde) das linhas indicando chuva (vermelha), exceto para os últimos parâmetros à direita da figura.

Os dados coletados estão dispostos em coordenadas paralelas para facilitar a visualização do comportamento dos elementos que geram a chuva.

Figura 13: Representação gráfica em coordenadas paralelas, na qual cada eixo representa uma variável meteorológica, para o período de 1996 até 2012.



Fonte: Estação Meteorológica da UNESP\*†.

Dentro desse cenário, foram utilizados dois tipos de RNAs para encontrar o balanço pluviométrico dentro do período estudado (1996-2012). Além disso, procurou-se reduzir as vinte e duas variáveis (variáveis independentes) existentes para precipitação da chuva na cidade de Presidente Prudente. Outro item a ser comentado é a procura de melhores coeficientes de cálculos (núcleos e composição da rede neural artificial) devolvendo um

† Dados fornecidos pela Estação Meteorológica da UNESP

resultado aceitável, ou seja, o coeficiente Kappa (resposta) deve estar dentro do aceitável.

Essa busca da minimização dos parâmetros de entrada (variáveis independentes ou elementos climáticos), e coeficientes de cálculos que retornem bons resultados, tem sua importância, pois as estações meteorológicas ou mesmo postos menores de coleta de dados, possivelmente trabalhariam com essas coletas, ou seja, seriam coletas de dados mais simplificadas com maior período de tempo e com aparelhos mais acessíveis a pequenos postos de coleta.

Para ajudar nesta busca das variáveis independentes ou elementos climáticos ideais, foi utilizado o conceito geográfico citado no Capítulo 2 que estuda a combinação dos elementos meteorológicos concomitantes e suas interações com a região abordada, ou seja, entendendo as interações que os elementos provocam em determinado momento é possível avaliar e identificar os elementos mais interessantes para o local estudado.

Os dois tipos de RNA's empregadas neste estudo foram a *Backpropagation* de Múltiplas Camadas (MLP) e Máquina de Vetor de Suporte (SVM), caracterizada e organizada conforme apresentado na Tabela 4.

Tabela 4: Descrição das modelagens empregadas e valores dos parâmetros utilizados.

Nome da Rede	Parâmetro interno da RNA
MLP1	22 neurônios de entrada, 23 neurônios na camada oculta e 2 saídas
MLP2	22 neurônios de entrada, 23 neurônios nas duas camadas ocultas e 2 saídas
MLP3	22 neurônios de entrada, 23 neurônios nas três camadas ocultas e 2 neurônios de saída
SVMp1	Núcleo polinomial com os parâmetros: Power = 1,0, Bias = 1,0, Gamma = 1,0
SVMp2	Núcleo polinomial com os parâmetros: Power = 2,0, Bias = 0,5, Gamma = 0,5
SVMp3	Núcleo polinomial com os parâmetros: Power = 1,5, Bias = 1,5, Gamma = 0,5
SVMrbf1	Núcleo de base função radial com o parâmetro: Sigma = 0,1
SVMrbf2	Núcleo de base função radial com o parâmetro: Sigma = 0,5
SVMrbf3	Núcleo de base função radial com o parâmetro: Sigma = 1,5
SVMsig1	Núcleo sigmoide com os parâmetros: Kappa = 0,1, Delta = 0,5
SVMsig2	Núcleo sigmoide com os parâmetros: Kappa = 0,5, Delta = 1,0
SVMsig3	Núcleo sigmoide com os parâmetros: Kappa = 1,5, Delta = 2,0

Fonte: O Autor.

Para melhor entender e visualizar os cálculos citados na Tabela 4 observa-se no Apêndice A de maneira fácil e ilustrada como o fluxo dos cálculos é executado e como se dá o fluxo completo da modelagem.

Todos os parâmetros de aprendizado da RNA, apresentados na Tabela 4, foram determinados por testes empíricos com o software *KNIME versão 2.9.4*. Para os parâmetros internos da rede MLP, utilizou-se 1, 2 e 3 camadas ocultas, com 22 neurônios. Sendo que cada neurônio representa uma entrada (variável independente ou elemento climático).

Na rede SVM, com núcleo polinomial, os valores dos parâmetros internos utilizados foram: *Power* de 1,0 a 2,0, *Bias* de 0,5 a 1,5 e *Gamma* de 0,5 a 1,0, todos com incremento de 0,5. O *Power* indica o poder de representação das características dos vetores ou dos hiperplanos, a *Bias* indica o valor constante de aprendizagem, e o *Gamma* indica o valor de

deslocamento do ajuste dos pesos (WERBOS, 1990; SCHÖLKOPF; DECOSTE, 2002).

Na rede SVM, com núcleo de função de base radial, os valores do parâmetro Sigma utilizados foram: 0,1, 0,5 e 1,5. O Sigma é usado para mapear os dados de entrada em um espaço de características  $f$ , onde cada coordenada corresponde a uma função gaussiana aplicada à distância de um determinado ponto no conjunto de treinamento (FLEISS, 2003; VAPNIK; CHERVONENKIS, 1971).

Na rede SVM, com núcleo hiper tangente ou sigmoide, os valores do parâmetro interno Kappa utilizados foram de 0,1, 0,5, e 1,5, e os valores do parâmetro Delta utilizados foram de 0,5, 1,0 e 2,0. O parâmetro Kappa indica a medida de concordância entre dois indivíduos, e o parâmetro Delta indica as diferenças entre as características de dois hiperplanos sucessivos (SASAKI, 2014).

Os resultados e a interpretação de todos os testes realizados foram auxiliados através da matriz de confusão e do coeficiente Kappa (resposta), além disso, para a identificação dos dias do mês de Janeiro de 2012 além de utilizar a matriz de confusão e o coeficiente Kappa (resposta) são inferidos porcentagens específicas de cada acerto e erro, relatado como falso positivo (FP), falso negativo (FN), verdadeiro positivo (VP) e verdadeiro negativo (VN).

## 5 EXPERIMENTOS E ANÁLISE DOS RESULTADOS

Como mencionado no capítulo anterior, foram utilizados dois tipos de RNA's, a *Backpropagation* de Múltiplas Camadas (MLP) e a Máquina de Vetor de Suporte (SVM).

Uma das maneiras encontradas para verificar a eficiência do reconhecimento da chuva e aprendizagem da rede, sugeriu-se a montagem e apresentação de uma análise da matriz de confusão e dos valores da variável Kappa (resposta) (FLEISS, 2003). De acordo com Landis e Kock (1977), coeficientes Kappa (resposta) que estão entre 0,00 à 0,19 são considerados “pobre”, entre 0,20 à 0,39 são considerados “considerável”, 0,40 à 0,59 são considerados “moderado”, 0,60 à 0,79 são considerados “substancial”, e de 0,80 à 1,00 são considerados “excelentes”.

Inicialmente, serão apresentados os resultados com todas as variáveis de entrada (elementos climáticos), posteriormente os resultados já com as reduções das variáveis de entrada (elementos climáticos) e, por último, uma análise final utilizando o melhor modelo identificado, contra o mês de Janeiro de 2012, encontrando os dias de “chuva” e “não chuva” para tal mês.

Nas Tabelas 5, 6 e 7 estão os resultados obtidos ao se utilizar a RNA MLP, com *backpropagation* e com uma camada oculta para os grupos de treinamento e testes um dois e três. Estes resultados foram obtidos com todas as variáveis de entrada (variáveis independentes ou elementos climáticos): **i)** Característica da variação da pressão nas últimas 3 horas; **ii)** Tipo da nuvem alta; **iii)** Tipo da nuvem baixa; **iv)** Tipo da nuvem média; **v)** Direção do vento de 0 a 360 graus; **vi)** Velocidade do vento em m/s; **vii)** Altura da base das nuvens na primeira camada em metros; **viii)** Cobertura das nuvens em %; **ix)** Cobertura das nuvens na primeira camada em oitavos; **x)** Pressão reduzida ao nível médio do mar em hPa; **xi)** Pressão ao nível da estação local em hPa; **xii)** Temperatura do ar °C; **xiii)** Ponto de orvalho °C; **xiv)** Temperatura mínima °C; **xv)** Período da precipitação acumulada em horas; **xvi)** Temperatura máxima °C; **xvii)** Umidade relativa do ar %; **xviii)** Visibilidade horizontal em metros; **xix)** Variação da pressão nas últimas 3 horas em hPa; **xx)** Tempo presente; **xxi)** Tempo passado1 e **xxii)** Tempo passado2.

Tabela 5: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com uma camada oculta para o grupo de teste um.

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	14	4	18	22,22%
Não Precipitação	3	403	406	0,74%
kappa(k) 0,791		Total Global	424	
			Acurácia	98,35%

Fonte: O Autor.

Tabela 6: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com uma camada oculta para o grupo de teste dois.

<i>Grupo de aprendizagem e teste 2</i>				
Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	16	2	18	11,11%
Não Precipitação	2	404	406	0,49%
kappa(k) 0,884		Total Global	424	
			Acurácia	99,06%

Fonte: O Autor.

Tabela 7: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com uma camada oculta para o grupo de teste três.

<i>Grupo de aprendizagem e teste 3</i>				
Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	16	2	18	11,11%
Não Precipitação	5	401	406	1,23%
kappa(k) 0,812		Total Global	424	
			Acurácia	98,35%

Fonte: O Autor.

As Tabelas 8, 9 e 10 apresentam os resultados obtidos ao se utilizar a RNA MLP, com o modelo *backpropagation* e duas camadas oculta para o grupo de treinamento um dois e três. Estes resultados foram obtidos ao se utilizar todas as variáveis de entrada (elementos climáticos).

Tabela 8: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com duas camadas ocultas para o grupo de teste um.

*Grupo de aprendizagem e teste 1*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	14	4	18	22,22%
Não Precipitação	6	400	406	1,48%
kappa(k) 0,725		Total Global	424	
			Acurácia	97,64%

Fonte: O Autor.

Tabela 9: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com duas camadas ocultas para o grupo de teste dois.

*Grupo de aprendizagem e teste 2*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	12	6	18	33,33%
Não Precipitação	1	405	406	0,25%
kappa(k) 0,766		Total Global	424	
			Acurácia	98,35%

Fonte: O Autor.

Tabela 10: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com duas camadas ocultas para o grupo de teste três.

*Grupo de aprendizagem e teste 3*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	15	3	18	16,67%
Não Precipitação	6	400	406	1,48%
kappa(k) 0,758		Total Global	424	
			Acurácia	97,88%

Fonte: O Autor.

A seguir são apresentadas as Tabelas 11, 12 e 13, também com todos os parâmetros de entrada (elementos climáticos) para a RNA MLP, com três camadas ocultas, para os grupos de treinamento e teste um, dois e três.

Tabela 11: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com três camadas ocultas para o grupo de teste um.

*Grupo de aprendizagem e teste 1*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	12	6	18	33,33%
Não Precipitação	2	404	406	0,49%
kappa(k) 0,74	Total Global		424	
			Acurácia	98,11%

Fonte: O Autor.

Tabela 12: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com três camadas ocultas para o grupo de teste dois.

*Grupo de aprendizagem e teste 2*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	15	3	18	16,67%
Não Precipitação	1	405	406	0,25%
kappa(k) 0,877	Total Global		424	
			Acurácia	99,06%

Fonte: O Autor.

Tabela 13: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com três camadas ocultas para o grupo de teste três.

*Grupo de aprendizagem e teste 3*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	16	2	18	11,11%
Não Precipitação	6	400	406	1,48%
kappa(k) 0,79	Total Global		424	
			Acurácia	98,11%

Fonte: O Autor.

Ao se analisar os valores de Kappa (resposta) observa-se que, em geral, os melhores resultados foram obtidos ao se utilizar uma camada oculta (Tabelas 5, 6 e 7). Estes resultados não foram avaliados para cada grupo de teste individualmente, mas para os três grupos de teste no geral. Desta forma, pode ser que a rede tenha obtido melhores resultados individuais, mas foi escolhido o conjunto com os melhores resultados globais para demonstrar a robustez do modelo gerado.

Para a rede MLP, com uma camada oculta, os valores de Kappa (resposta) variam entre 0,781 a 0,884, demonstrando um bom poder de identificação do padrão (LANDIS; KOCK, 1977). Pode-se notar ainda que o total de dias que “não chove”, é maior do que os dias que “chove”, por isso, as análises devem ser focadas no acerto dos dias em que há precipitação. Para estes modelos, o erro na identificação da precipitação variou de 11,11% a 22,22% (Tabelas 5, 6 e 7).

Em seguida, realizou-se os testes com SVM e núcleo função de base radial, polinomial e hiper tangente (sigmoide), utilizando todos os parâmetros (variáveis independentes ou elementos climáticos).

As Tabelas 14,15 e 16 apresentam os resultados obtidos com o emprego da SVM com núcleo (rbf) para os grupos de teste um dois e três.

Tabela 14: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo função de base radial e parâmetro Sigma igual a 1,5, para o grupo de teste um.

<i>Grupo de aprendizagem e teste 1</i>				
Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	14	4	18	22,22%
Não Precipitação	8	398	406	1,97%
kappa(k) 0,816	Total Global		424	
			Acurácia	97,17%

Fonte: O Autor.

Tabela 15: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo função de base radial e parâmetro Sigma igual a 1,5, para o grupo de teste dois.

<i>Grupo de aprendizagem e teste 2</i>				
Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	16	2	18	11,11%
Não Precipitação	0	406	406	0,00%
kappa(k) 0,939	Total Global		424	
			Acurácia	99,53%

Fonte: O Autor.

Tabela 16: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo função de base radial e parâmetro Sigma igual a 1,5, para o grupo de teste três.

<i>Grupo de aprendizagem e teste 3</i>				
Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	15	3	18	16,67%
Não Precipitação	4	402	406	0,99%
kappa(k) 0,802	Total Global		424	
			Acurácia	98,35%

Fonte: O Autor.

Observando as Tabelas 14, 15 e 16, nota-se que ao utilizar a SVM com núcleo rbf, juntamente com os coeficientes adequados e um conjunto de dados robusto é possível chegar muito próximo dos 100% de acerto, pois de acordo com Landis e Kock (1977), os valores de Kappa (resposta) obtidos são “excelentes”. Os valores de Kappa, para estas análises, variaram de 0,802 a 0,939 e os erros na identificação dos dias com precipitação variaram de 11,11% a 22,22%.

As Tabelas 17, 18 e 19 apresentam os resultados obtidos para a SVM de núcleo rbf, com o valor do coeficiente interno Sigma igual a 0,1, para o grupo de treinamento com todos os parâmetros de entrada.

Tabela 17: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo função de base radial e parâmetro Sigma igual a 0,1, para o grupo de teste um.

<i>Grupo de aprendizagem e teste 1</i>				
Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0	Total Global		424	
			Acurácia	95,76%

Fonte: O Autor.

Tabela 18: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo função de base radial e parâmetro Sigma igual a 0,1, para o grupo de teste dois.

<i>Grupo de aprendizagem e teste 2</i>				
Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0		Total Global	424	
			Acurácia	95,76%

Fonte: O Autor.

Tabela 19: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo função de base radial e com parâmetro Sigma igual a 0,1, para o grupo de teste três.

<i>Grupo de aprendizagem e teste 3</i>				
Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0		Total Global	424	
			Acurácia	95,76%

Fonte: O Autor.

Nestes resultados é possível observar que a precisão dos cálculos alcança 95,76% de acerto. Entretanto, pode-se dizer que estes resultados não são bons, pois o objetivo da RNA é realizar a identificação de chuva. Os resultados mostram que para os três cálculos, o total de acerto para os dias de chuva foi zero. Considerando que a quantidade de dias com chuva é muito menor do que os dias sem chuva, a precisão da identificação alcançou mais do que 95% de acerto. Nota-se também que os valores de Kappa não puderam ser calculados nestas análises.

As Tabelas 20, 21 e 22 apresentam os resultados obtidos para a rede neural SVM de núcleo rbf, com coeficiente interno Sigma igual a 0,5, para os grupos de treinamento de teste um dois e três.

Tabela 20: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo função de base radial e parâmetro Sigma igual a 0,5, para o grupo de teste um.

*Grupo de aprendizagem e teste 1*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	13	5	18	27,78%
Não Precipitação	2	404	406	0,49%
kappa(k) 0,779	Total Global		424	
			Acurácia	98,35%

Fonte: O Autor.

Tabela 21: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo função de base radial e parâmetro Sigma igual a 0,5, para o grupo de teste dois.

*Grupo de aprendizagem e teste 2*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	16	2	18	11,11%
Não Precipitação	0	406	406	0,00%
kappa(k) 0,939	Total Global		424	
			Acurácia	99,53%

Fonte: O Autor.

Tabela 22: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo função de base radial e parâmetro Sigma igual a 0,5, para o grupo de teste três.

*Grupo de aprendizagem e teste 3*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	15	3	18	16,67%
Não Precipitação	4	402	406	0,99%
kappa(k) 0,802	Total Global		424	
			Acurácia	98,35%

Fonte: O Autor.

Apesar de estas análises apresentarem um excelente resultado, dentro da classificação de Landis e Kock (1977), no geral foi analisado o

conjunto como um todo. Desta forma, as Tabelas 14, 15 e 16, obtidas com o emprego da rede neural artificial SVM com núcleo função de base radial e parâmetro Sigma igual a 1,5, foram as que apresentam os melhores resultados utilizando todas as variáveis de entrada.

As Tabelas 23, 24 e 25 apresentam os resultados obtidos com a rede neural artificial SVM de núcleo polinomial, com os coeficientes internos Power igual a 1,0, Bias igual a 1,0 e Gamma igual a 1,0, utilizando-se todos os parâmetros de entrada.

Tabela 23: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo polinomial, com os valores dos parâmetros Power igual a 1,0, Bias igual a 1,0 e Gamma igual a 1,0, para o grupo de teste um.

<i>Grupo de aprendizagem e teste 1</i>				
Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	14	4	18	22,22%
Não Precipitação	2	404	406	0,49%
kappa(k) 0,816	Total Global		424	
			Acurácia	98,59%

Fonte: O Autor.

Tabela 24: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo polinomial, com os valores dos parâmetros Power igual a 1,0, Bias igual a 1,0 e Gamma igual a 1,0, para o grupo de teste dois.

<i>Grupo de aprendizagem e teste 2</i>				
Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	14	4	18	22,22%
Não Precipitação	0	406	406	0,00%
kappa(k) 0,87	Total Global		424	
			Acurácia	99,06%

Fonte: O Autor.

Tabela 25: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo polinomial, com os valores dos parâmetros Power

igual a 1,0, Bias igual a 1,0 e Gamma igual a 1,0, para o grupo de teste três.

*Grupo de aprendizagem e teste 3*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	15	3	18	16,67%
Não Precipitação	2	404	406	0,49%
kappa(k) 0,851		Total Global	424	
			Acurácia	98,82%

Fonte: O Autor.

As Tabelas 26, 27 e 28 apresentam os resultados obtidos com a rede neural artificial SVM de núcleo polinomial, com os coeficientes internos Power igual a 2,0, Bias igual a 0,5 e Gamma igual a 0,5, utilizando-se todos os parâmetros de entrada.

Tabela 26: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo polinomial, com os valores dos parâmetros Power igual a 2,0, Bias igual a 0,5 e Gamma igual a 0,5, para o grupo de teste um.

*Grupo de aprendizagem e teste 1*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	17	1	18	5,56%
Não Precipitação	4	402	406	0,99%
kappa(k) 0,866		Total Global	424	
			Acurácia	98,82%

Fonte: O Autor.

Tabela 27: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo polinomial, com os valores dos parâmetros Power igual a 2,0, Bias igual a 0,5 e Gamma igual a 0,5, para o grupo de teste dois.

*Grupo de aprendizagem e teste 2*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	16	2	18	11,11%
Não Precipitação	2	404	406	0,49%
kappa(k) 0,884	Total Global		424	
			Acurácia	99,06%

Fonte: O Autor.

Tabela 28: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo polinomial, com os valores dos parâmetros Power igual a 2,0, Bias igual a 0,5 e Gamma igual a 0,5, para o grupo de teste três.

*Grupo de aprendizagem e teste 3*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	15	3	18	16,67%
Não Precipitação	5	401	406	1,23%
kappa(k) 0,78	Total Global		424	
			Acurácia	98,11%

Fonte: O Autor.

As Tabelas 29, 30 e 31 apresentam os resultados obtidos com a rede neural artificial SVM de núcleo polinomial, com os coeficientes internos Power igual a 1,5, Bias igual a 1,5 e Gamma igual a 0,5, utilizando-se todos os parâmetros de entrada.

Tabela 29: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo polinomial, com os valores dos parâmetros Power igual a 1,5, Bias igual a 1,5 e Gamma igual a 0,5, para o grupo de teste um.

*Grupo de aprendizagem e teste 1*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	16	2	18	11,11%
Não Precipitação	3	403	406	0,74%
kappa(k) 0,859	Total Global		424	
			Acurácia	98,82%

Fonte: O Autor.

Tabela 30: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo polinomial, com os valores dos parâmetros Power igual a 1,5, Bias igual a 1,5 e Gamma igual a 0,5, para o grupo de teste dois.

*Grupo de aprendizagem e teste 2*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	15	3	18	16,67%
Não Precipitação	1	405	406	0,25%
kappa(k) 0,877	Total Global		424	
			Acurácia	99,06%

Fonte: O Autor.

Tabela 31: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo polinomial, com os valores dos parâmetros Power igual a 1,5, Bias igual a 1,5 e Gamma igual a 0,5, para o grupo de teste três.

*Grupo de aprendizagem e teste 3*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	15	3	18	16,67%
Não Precipitação	4	402	406	0,99%
kappa(k) 0,802	Total Global		424	
			Acurácia	98,35%

Fonte: O Autor.

Com os resultados das Tabelas 23, 24, 25, 26, 27, 28, 29, 30 e 31 também mostram excelentes resultados dentro da classificação de Landis e Kock (1977).

A análise dos resultados obtidos ao se utilizar a rede neural SVM de núcleo polinomial forneceu, de uma maneira geral, bons resultados. Em todas as análises os valores de kappa calculados foram superiores á 0,8. A alteração nos valores dos parâmetros Power, Bias e Gamma causam uma pequena variação na porcentagem de acerto da RNA. Entretanto, os resultados obtidos com a SVM com núcleo função de base radial foram superiores aos encontrados no SVM de núcleo polinomial.

A seguir as Tabelas 32, 33 e 34 apresentam os resultados obtidos para a rede neural artificial SVM com núcleo hiper tangente, utilizando os parâmetros internos kappa igual a 0,1 e Delta igual a 0,5, com todos os parâmetros de entrada.

Tabela 32: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo hyper tangente, com os valores dos parâmetros kappa igual a 0,1 e Delta igual a 0,5, para o grupo de teste um.

*Grupo de aprendizagem e teste 1*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	3	403	406	0,74%
kappa(k) -0,012		Total Global	424	
			Acurácia	95,05%

Fonte: O Autor.

Tabela 33: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo hiper tangente, com os valores dos parâmetros kappa igual a 0,1 e Delta igual a 0,5, para o grupo de teste dois.

*Grupo de aprendizagem e teste 2*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0		Total Global	424	
			Acurácia	95,76%

Fonte: O Autor.

Tabela 34: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo hiper tangente, com os valores dos parâmetros kappa igual a 0,1 e Delta igual a 0,5, para o grupo de teste três.

*Grupo de aprendizagem e teste 3*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	2	404	406	0,49%
kappa(k) -0,009		Total Global	424	
			Acurácia	95,28%

Fonte: O Autor.

As Tabelas 35, 36 e 37 apresentam os resultados obtidos para a rede neural artificial SVM com núcleo hiper tangente, utilizando os parâmetros internos kappa igual a 0,5 e Delta igual a 1,0, com todos os parâmetros de entrada.

Tabela 35: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo hiper tangente, com os valores dos parâmetros kappa igual a 0,5 e Delta igual a 1,0, para o grupo de teste um.

*Grupo de aprendizagem e teste 1*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0		Total Global	424	
			Acurácia	95,76%

Fonte: O Autor.

Tabela 36: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo hiper tangente, com os valores dos parâmetros kappa igual a 0,5 e Delta igual a 1,0, para o grupo de teste dois.

*Grupo de aprendizagem e teste 2*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0		Total Global	424	
			Acurácia	95,76%

Fonte: O Autor.

Tabela 37: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM com núcleo hiper tangente, com os valores dos parâmetros kappa igual a 0,5 e Delta igual a 1,0, para o grupo de teste três.

<i>Grupo de aprendizagem e teste 3</i>				
Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	1	405	406	0,25%
kappa(k) -0,004		Total Global	424	
			Acurácia	95,52%

Fonte: O Autor.

A análise das Tabelas 32 a 34 e 35 a 37, obtidas com a RNA SVM com núcleo hiper tangente não forneceram bons resultados. Todas as seis análises não conseguiram identificar a precipitação, indicando que o modelo não pode ser aplicado neste conjunto de dados.

Ao se comparar os resultados entre os dois melhores modelos, *backpropagation*, com vinte e três neurônios e com uma camada oculta (Tabelas 5, 6 e 7), contra o modelo SVM com função de base radial, com os valores do parâmetro sigma igual a 1,5, (Tabelas 14, 15 e 16), observa-se que o modelo SVM rbf além de demonstrar o melhor resultado individualmente, Tabela 14, também demonstra um melhor equilíbrio e robustez do conjunto de dados como um todo.

Em seguida, foram realizadas gradativas exclusões dos parâmetros de entrada (variáveis independentes), para tentar simplificar a compreensão da movimentação climatológica e atingir iguais resultados nas RNA's. As reduções de variáveis foram auxiliadas pela teoria meteorológica e rítmica climatológica trabalhada por Monteiro (1991), Boin (2000), Zavattini (2004) e Zavattini e Boin (2013).

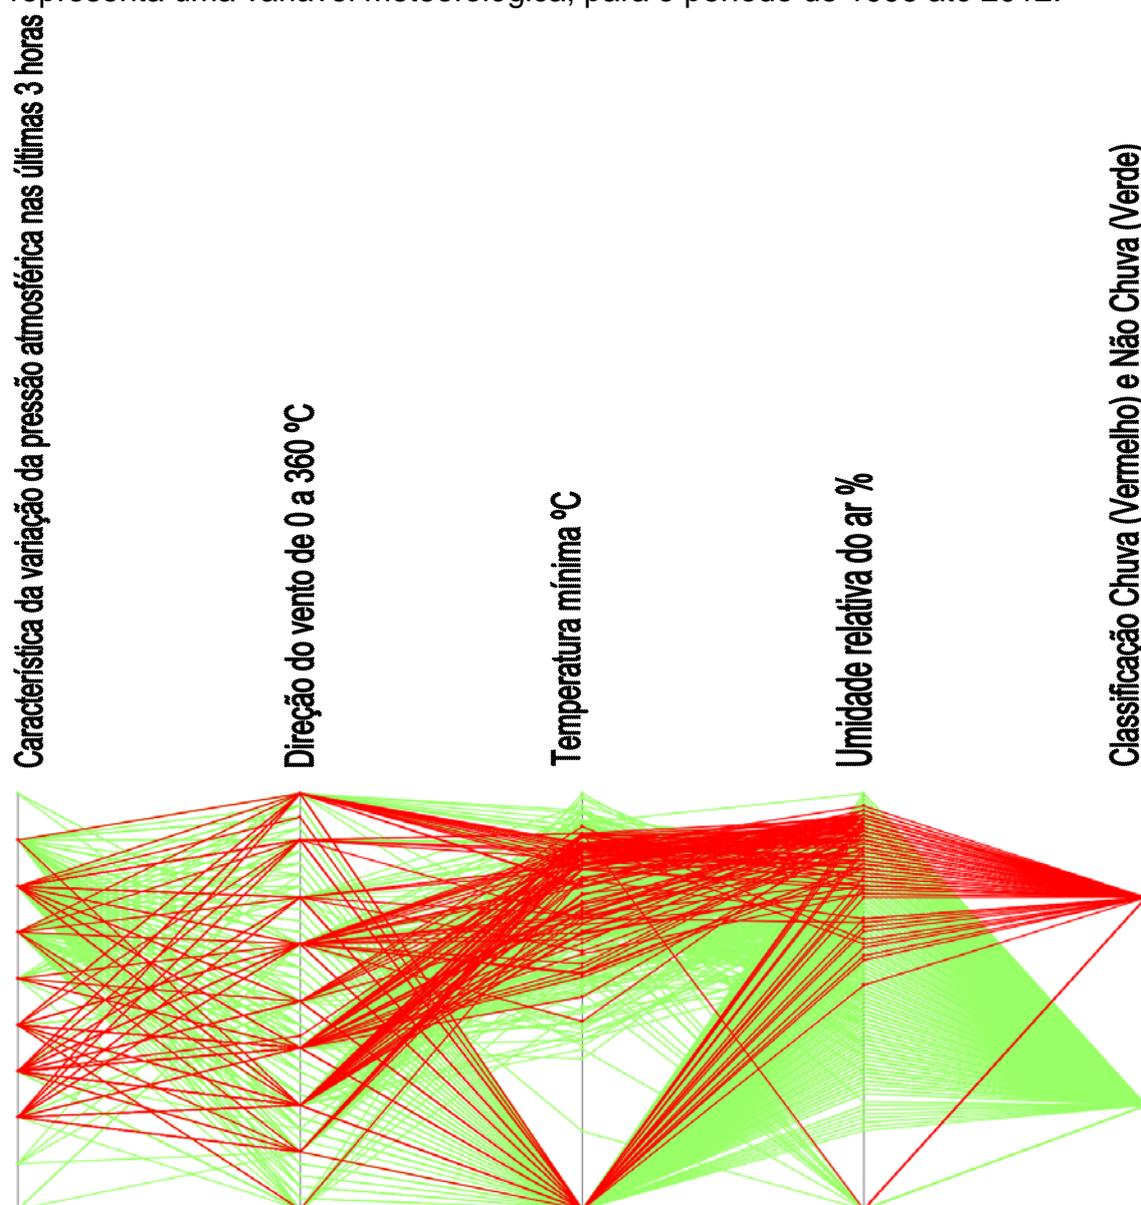
Os melhores resultados foram obtidos ao se utilizar quatro parâmetros: **i)** Característica da variação da pressão atmosférica nas últimas 3 horas; **ii)** Direção do vento de 0 a 360 graus; **iii)** Temperatura mínima °C e **iv)** Umidade relativa do ar %.

A Figura a seguir demonstra-se as coordenadas paralelas com quatro parâmetros de entrada. É possível observar que as cores verdes (não chuva) e vermelhas (chuva) estão mais distintas em relação à Figura 14, ou

seja, há uma maior possibilidade visual de reconhecimento do padrão da chuva.

Estas coordenadas paralelas demonstram o comportamento das variáveis que estão sendo analisadas e o movimento dos elementos gerando a chuva, sendo assim, é fácil observar como o ritmo climatológico e os dados meteorológicos se comportam durante a série temporal de dados analisados em questão.

Figura 14: Representação gráfica em coordenadas paralelas, na qual cada eixo representa uma variável meteorológica, para o período de 1996 até 2012.



Fonte: Estação Meteorológica da UNESP\*<sup>†</sup>.

<sup>†</sup> Dados fornecidos pela Estação Meteorológica da UNESP.

Nas próximas tabelas serão apresentados os resultados obtidos para a RNA MLP, com uma camada oculta, estão apresentados nas Tabelas 38, 39 e 40, respectivamente para os grupos de teste 1, 2 e 3. Estes resultados foram obtidos utilizando-se apenas quatro variáveis de entrada.

Tabela 38: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com uma camada oculta, para o grupo de teste um.

<i>Grupo de aprendizagem e teste 1</i>				
Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	14	4	18	22,22%
Não Precipitação	4	402	406	0,99%
kappa(k) 0,611		Total Global	424	
			Acurácia	97,17%

Fonte: O Autor.

Tabela 39: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com uma camada oculta, para o grupo de teste dois.

<i>Grupo de aprendizagem e teste 2</i>				
Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	15	3	18	16,67%
Não Precipitação	4	402	406	0,99%
kappa(k) 0,802		Total Global	424	
			Acurácia	98,35%

Fonte: O Autor.

Tabela 40: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com uma camada oculta, para o grupo de teste três.

<i>Grupo de aprendizagem e teste 3</i>				
Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	14	4	18	22,22%
Não Precipitação	6	400	406	1,48%
kappa(k) 0,725		Total Global	424	
			Acurácia	97,64%

Fonte: O Autor.

Apesar das Tabelas 38, 39 e 40 apresentarem valores kappa (resultados), “substancial” e “excelente” dentro da classificação de Landis e Kock (1977), pode-se considerar que este modelo é melhor do que os primeiros que foram obtidos com todas as variáveis de entrada (22 no total). Pode-se realizar esta consideração, pois o número de variáveis utilizadas nesta análise é menor o que faz com que a interpretação, emparelhamento das movimentações climáticas com os modelos matemáticos e a geração dos resultados fiquem mais fáceis de compreender e analisar.

As Tabelas 41, 42 e 43 apresentam os resultados obtidos para a RNA MLP, com duas camadas ocultas, para os grupos de teste 1, 2 e 3, obtidos com quatro variáveis de entrada.

Tabela 41: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com duas camadas ocultas para o grupo de teste um.

<i>Grupo de aprendizagem e teste 1</i>				
Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	9	9	18	50,00%
Não Precipitação	1	405	406	0,25%
kappa(k) 0,632		Total Global	424	
			Acurácia	97,64%

Fonte: O Autor.

Tabela 42: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com duas camadas ocultas para o grupo de teste dois.

<i>Grupo de aprendizagem e teste 2</i>				
Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	11	7	18	38,89%
Não Precipitação	5	401	406	1,23%
kappa(k) 0,632		Total Global	424	
			Acurácia	97,17%

Fonte: O Autor.

Tabela 43: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com duas camadas ocultas para o grupo de teste três.

*Grupo de aprendizagem e teste 3*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	12	6	18	33,33%
Não Precipitação	4	402	406	0,99%
kappa(k) 0,694	Total Global		424	
			Acurácia	97,64%

Fonte: O Autor.

As Tabelas 44, 45 e 46 apresentam os resultados obtidos para a RNA MLP, com três camadas ocultas, para os grupos de teste 1, 2 e 3, obtidos com quatro variáveis de entrada.

Tabela 44: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com três camadas ocultas para o grupo de teste um.

*Grupo de aprendizagem e teste 1*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	10	8	18	44,44%
Não Precipitação	4	402	406	0,99%
kappa(k) 0,611	Total Global		424	
			Acurácia	97,17%

Fonte: O Autor.

Tabela 45: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com três camadas ocultas para o grupo de teste dois.

*Grupo de aprendizagem e teste 2*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	11	7	18	38,89%
Não Precipitação	4	402	406	0,99%
kappa(k) 0,653	Total Global		424	
			Acurácia	97,41%

Fonte: O Autor.

Tabela 46: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial MLP, com três camadas ocultas para o grupo de teste três.

<i>Grupo de aprendizagem e teste 3</i>				
Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	10	8	18	44,44%
Não Precipitação	7	399	406	1,72%
kappa(k) 0,553	Total Global		424	
			Acurácia	96,46%

Fonte: O Autor.

As análises realizadas com a RNA MLP com duas e três camadas ocultas forneceram resultados inferiores aos obtidos com uma camada oculta.

A seguir, as Tabelas 47, 48 e 49 apresentam os resultados obtidos ao se utilizar modelos SVM com núcleo função de base radial, com os mesmos quatro parâmetros de entrada, para os grupos de teste 1, 2 e 3, respectivamente.

Tabela 47: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo função de base radial, com o valor do parâmetro Sigma igual a 0,1, para o grupo de teste um.

<i>Grupo de aprendizagem e teste 1</i>				
Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	11	7	18	38,89%
Não Precipitação	3	403	406	0,74%
kappa(k) 0,675	Total Global		424	
			Acurácia	97,64%

Fonte: O Autor.

Tabela 48: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo função de base radial, com o valor do parâmetro Sigma igual a 0,1, para o grupo de teste dois.

*Grupo de aprendizagem e teste 2*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	14	4	18	22,22%
Não Precipitação	5	401	406	1,23%
kappa(k) 0,746	Total Global		424	
			Acurácia	97,88%

Fonte: O Autor.

Tabela 49: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo função de base radial, com o valor do parâmetro Sigma igual a 0,1, para o grupo de teste três.

*Grupo de aprendizagem e teste 3*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	15	3	18	16,67%
Não Precipitação	3	403	406	0,74%
kappa(k) 0,826	Total Global		424	
			Acurácia	98,58%

Fonte O Autor.

As Tabelas 50, 51 e 52 apresentam os resultados obtidos ao se utilizar o modelo SVM com núcleo rbf e valor do parâmetro Sigma igual a 0,5, com os mesmos quatro parâmetros de entrada, para os grupos de teste 1, 2 e 3, respectivamente.

Tabela 50: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo função de base radial, com o valor do parâmetro Sigma igual a 0,5, para o grupo de teste um.

*Grupo de aprendizagem e teste 1*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	10	8	18	44,44%
Não Precipitação	4	402	406	0,99%
kappa(k) 0,611	Total Global		424	
			Acurácia	97,17%

Fonte: O Autor.

Tabela 51: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo função de base radial, com o valor do parâmetro Sigma igual a 0,5, para o grupo de teste dois.

*Grupo de aprendizagem e teste 2*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	14	4	18	22,22%
Não Precipitação	5	401	406	1,23%
kappa(k) 0,746	Total Global		424	
			Acurácia	97,88%

Fonte: O Autor.

Tabela 52: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo função de base radial, com o valor do parâmetro Sigma igual a 0,5, para o grupo de teste três.

*Grupo de aprendizagem e teste 3*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	15	3	18	16,67%
Não Precipitação	3	403	406	0,74%
kappa(k) 0,826	Total Global		424	
			Acurácia	98,58%

Fonte: O Autor.

As Tabelas 53, 54 e 55 apresentam os resultados obtidos ao se utilizar o modelo SVM com núcleo rbf e valor do parâmetro Sigma igual a 1,5, com os mesmos quatro parâmetros de entrada, para os grupos de teste 1, 2 e 3, respectivamente.

Tabela 53: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo função de base radial, com o valor do parâmetro Sigma igual a 1,5, para o grupo de teste um.

*Grupo de aprendizagem e teste 1*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0	Total Global		424	
			Acurácia	95,75%

Fonte: O Autor.

Tabela 54: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo função de base radial, com o valor do parâmetro Sigma igual a 1,5, para o grupo de teste dois.

*Grupo de aprendizagem e teste 2*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0		Total Global	424	
			Acurácia	95,75%

Fonte: O Autor.

Tabela 55: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo função de base radial, com o valor do parâmetro Sigma igual a 1,5, para o grupo de teste três.

*Grupo de aprendizagem e teste 3*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0		Total Global	424	
			Acurácia	95,75%

Fonte: O Autor.

Novamente, considerando que as análises são realizadas ao se observar o valor de Kappa (resposta), pode-se dizer que precisão de 95,75%, obtido para a SVM com rbf e Sigma igual a 1,5, é ilusória em relação à busca de “chuva”, pois a quantidade de dados de “não chuva” dentro do conjunto de dados é bem maior do que a quantidade de dados de “chuva”.

As Tabelas 56, 57 e 58 apresentam os resultados obtidos ao se utilizar o modelo SVM com núcleo polinomial e valores dos parâmetros Power igual a 2,0, Bias igual a 0,5 e Gamma igual a 0,5, com os mesmos quatro parâmetros de entrada, para os grupos de teste 1, 2 e 3, respectivamente.

Tabela 56: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo polinomial, com os valores dos parâmetros Power igual a 2,0, Bias igual a 0,5 e Gamma igual a 0,5, para o grupo de teste um.

*Grupo de aprendizagem e teste 1*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0		Total Global	424	
			Acurácia	95,75%

Fonte: O Autor.

Tabela 57: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo polinomial, com os valores dos parâmetros Power igual a 2,0, Bias igual a 0,5 e Gamma igual a 0,5, para o grupo de teste dois.

*Grupo de aprendizagem e teste 2*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0		Total Global	424	
			Acurácia	95,75%

Fonte: O Autor.

Tabela 58: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo polinomial, com os valores dos parâmetros Power igual a 2,0, Bias igual a 0,5 e Gamma igual a 0,5, para o grupo de teste três.

*Grupo de aprendizagem e teste 3*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0		Total Global	424	
			Acurácia	95,75%

Fonte: O Autor.

As Tabelas 56, 57 e 58 apesar de terem 95,75% de precisão não possuem um bom poder de identificação, considerando que o valor real a ser observado é o do kappa. Em todas estas três análises o kappa foi zero, como ocorreu nas Tabelas 53, 54 e 55.

As Tabelas 59, 60 e 61 apresentam os resultados obtidos ao se utilizar o modelo SVM com núcleo polinomial e valores dos parâmetros Power igual a 1,5, Bias igual a 1,5 e Gamma igual a 0,5, com os mesmos quatro parâmetros de entrada, para os grupos de teste 1, 2 e 3, respectivamente.

Tabela 59: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo polinomial, com os valores dos parâmetros Power igual a 1,5, Bias igual a 1,5 e Gamma igual a 0,5, para o grupo de teste um.

*Grupo de aprendizagem e teste 1*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0	Total Global		424	
			Acurácia	95,75%

Fonte: O Autor.

Tabela 60: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo polinomial, com os valores dos parâmetros Power igual a 1,5, Bias igual a 0,5 e Gamma igual a 0,5, para o grupo de teste dois.

*Grupo de aprendizagem e teste 2*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0	Total Global		424	
			Acurácia	95,75%

Fonte: O Autor.

Tabela 61: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo polinomial, com os valores dos parâmetros Power igual a 1,5, Bias igual a 0,5 e Gamma igual a 0,5, para o grupo de teste três.

*Grupo de aprendizagem e teste 3*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0		Total Global	424	
			Acurácia	95,75%

Fonte: O Autor.

Neste caso também ocorreu valor zero no coeficiente Kappa. Este fato ocorre devido á incapacidade da SVM em separar os dados em hiper planos, ou seja, a SVM não consegue encontrar uma margem máxima entre os dados de treinamento.

As Tabelas 62, 63 e 64 apresentam os resultados obtidos ao se utilizar o modelo SVM com núcleo polinomial e valores dos parâmetros Power igual a 1,0, Bias igual a 1,0 e Gamma igual a 1,0, com os mesmos quatro parâmetros de entrada, para os grupos de teste 1, 2 e 3, respectivamente.

Tabela 62: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo polinomial, com os valores dos parâmetros Power igual a 1,0, Bias igual a 1,0 e Gamma igual a 1,0, para o grupo de teste um.

*Grupo de aprendizagem e teste 1*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0		Total Global	424	
			Acurácia	95,75%

Fonte: O Autor.

Tabela 63: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo polinomial, com os valores dos parâmetros Power igual a 1,0, Bias igual a 1,0 e Gamma igual a 1,0, para o grupo de teste dois.

*Grupo de aprendizagem e teste 2*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0	Total Global		424	
			Acurácia	95,75%

Fonte: O Autor.

Tabela 64: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo polinomial, com os valores dos parâmetros Power igual a 1,0, Bias igual a 1,0 e Gamma igual a 1,0, para o grupo de teste três.

*Grupo de aprendizagem e teste 3*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0	Total Global		424	
			Acurácia	95,75%

Fonte: O Autor.

Novamente, os valores de Kappa foram zero, indicando que este modelo não pode ser utilizado na identificação de precipitação, com estas variáveis selecionadas.

As Tabelas 65, 66 e 67 apresentam os resultados obtidos ao se utilizar modelos SVM com núcleo hiper tangente e valores dos parâmetros Kappa igual a 0,1 e Delta igual a 0,5, com os mesmos quatro parâmetros de entrada, para os grupos de teste 1, 2 e 3, respectivamente. Essas tabelas apesar de demonstrarem 95,75% de identificação da precipitação, não são relevantes, pois o valor Kappa (resposta) é igual a 0.

Tabela 65: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo hiper tangente, com valores dos parâmetros Kappa igual a 0,1 e Delta igual a 0,5, para o grupo de teste um.

*Grupo de aprendizagem e teste 1*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0		Total Global	424	
			Acurácia	95,75%

Fonte: O Autor.

Tabela 66: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo hiper tangente, com os valores dos parâmetros Kappa igual a 0,1 e Delta igual a 0,5, para o grupo de teste dois.

*Grupo de aprendizagem e teste 2*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0		Total Global	424	
			Acurácia	95,75%

Fonte: O Autor.

Tabela 67: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo hiper tangente, com os valores dos parâmetros Kappa igual a 0,1 e Delta igual a 0,5, para o grupo de teste três.

*Grupo de aprendizagem e teste 3*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0		Total Global	424	
			Acurácia	95,28%

Fonte: O Autor.

As Tabelas 68, 69, 70 apresentam os resultados obtidos ao se utilizar o modelo SVM com núcleo hiper tangente e valores dos parâmetros Kappa igual a 0,5 e Delta igual a 1,0, com os mesmos quatro parâmetros de entrada, para os grupos de teste 1, 2 e 3, respectivamente. Nos três modelos os valores de kappa são irrelevantes, indicando que o mesmo não pode ser utilizado para a identificação da precipitação com estes parâmetros de entrada.

Tabela 68: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo hiper tangente, com valores dos parâmetros Kappa igual a 0,5 e Delta igual a 1,0, para o grupo de teste um.

*Grupo de aprendizagem e teste 1*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	1	405	406	0,25%
kappa(k) -0,004		Total Global	424	
			Acurácia	95,52%

Fonte: O Autor.

Tabela 69: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo hiper tangente, com os valores dos parâmetros Kappa igual a 0,5 e Delta igual a 1,0, para o grupo de teste dois.

*Grupo de aprendizagem e teste 2*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	1	405	406	0,25%
kappa(k) -0,004		Total Global	424	
			Acurácia	95,52%

Fonte: O Autor.

Tabela 70: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo hiper tangente, com os valores dos parâmetros Kappa igual a 0,5 e Delta igual a 1,0, para o grupo de teste três.

*Grupo de aprendizagem e teste 3*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0		Total Global	424	
			Acurácia	95,52%

Fonte: O Autor.

As Tabelas 71, 72 e 73 apresentam os resultados obtidos ao se utilizar o modelo SVM com núcleo hiper tangente e valores dos parâmetros Kappa igual a 1,5 e Delta igual a 2,0, com os mesmos quatro parâmetros de entrada, para os grupos de teste 1, 2 e 3, respectivamente. Novamente os valores de kappa foram iguais a zero.

Tabela 71: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo hiper tangente, com valores dos parâmetros Kappa igual a 1,5 e Delta igual a 2,0, para o grupo de teste um.

*Grupo de aprendizagem e teste 1*

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0		Total Global	424	
			Acurácia	95,75%

Fonte: O Autor.

Tabela 72: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo hiper tangente, com valores dos parâmetros Kappa igual a 1,5 e Delta igual a 2,0, para o grupo de teste dois.

<i>Grupo de aprendizagem e teste 2</i>				
Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0		Total Global	424	
			Acurácia	95,75%

Fonte: O Autor.

Tabela 73: Matriz de confusão da classificação de precipitação e não precipitação obtida com o emprego da rede neural artificial SVM, com núcleo hiper tangente, com valores dos parâmetros Kappa igual a 1,5 e Delta igual a 2,0, para o grupo de teste três.

<i>Grupo de aprendizagem e teste 3</i>				
Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	0	18	18	100,00%
Não Precipitação	0	406	406	0,00%
kappa(k) 0		Total Global	424	
			Acurácia	95,75%

Fonte: O Autor.

Devido as Tabelas 71, 72 e 73 os valores de kappa (resposta) forem iguais á zero, ou seja, são considerados valores não aceitáveis para este trabalho.

Os resultados apresentados nas Tabelas 47, 48 e 49, obtidos ao se empregar o SVM (rbf e sigma igual 0,1) foram qualitativamente superiores aos obtidos pelo MLP, cujos resultados estão apresentados nas Tabelas 38, 39 e 40 (uma camada oculta). Deste modo, pode-se dizer que mesmo utilizando apenas quatro variáveis meteorológicas, é possível realizar os estudos de reconhecimento de padrão da precipitação através de RNA.

Com esses resultados, é possível indicar que a modelagem de retro propagação e máquina de vetor de suporte, utilizadas neste estudo possuem um alto índice de acerto, mesmo quando a quantidade de variáveis é reduzida, sendo que a etapa mais complexa está na determinação das variáveis meteorológicas de entrada correta.

Uma vez determinada as variáveis de entrada, a força computacional do algoritmo advém de dois principais atributos, na qual a RNA MLP utiliza um método local para atualizar os pesos sinápticos e os níveis de bias do perceptron múltiplas camadas e o segundo modelo matemático (SVM) é o método eficiente de calcular todas as derivadas parciais da função de custo (medida de desempenho) em relação a estes parâmetros livres (elementos climatológicos ou parâmetros independentes) (HAYKIN, 2001).

Para uma determinada época ou ciclo de treinamento da RNA MLP, o algoritmo de retro propagação operado nesse estudo, realiza operações por lote, sendo que os pesos sinápticos de todos os neurônios e bias da rede são ajustados a cada época/ciclo, resultando em uma forma mais precisa do vetor de gradiente. Nessa classificação o padrão não linearmente separável trabalha em todos os neurônios, ou seja, uma rede não linear.

A não linearidade é obtida pelo uso de uma função sigmoide, cujas funções tipicamente utilizadas na ativação do neurônio são: função logística, função tangente hiperbólica e degrau, descritas na fundamentação teórica de rede neural artificial.

Entretanto, durante as análises dos dados obtidos através do modelo SVM houve hipóteses de que quanto mais robusto os cálculos melhores seriam os resultados, e que na realidade não depende somente do cálculo, mas do conjunto que está sendo analisado e qual modelagem tem maior aderência aos resultados, além de ter maior velocidade na aprendizagem.

Sendo assim, a SVM inclui aprendizagem polinomial, rede de função radial, e tangente hiperbólica (sigmoide), que é basicamente diferente da retropropagação, pois a SVM utiliza aprendizado somente por lote. Outra diferença é a minimização da perda quadrática ou custo, sendo que a SVM quando realiza uma tarefa de classificação de padrão, o algoritmo de aprendizagem minimiza o número de amostras de treinamento que se encontram na margem de separação entre exemplos positivos e negativos (VAPNIK; CHERVONENKIS, 1971; IVANCIUC, 2007).

Em um contexto geral, as saídas da SVM são funções lineares, conseguindo controlar a complexidade do modelo, independente da dimensionalidade. Essa complexidade é solucionada em um espaço de alta

dimensionalidade, através da utilização de um hiperplano definido no espaço virtual, denominada de superfície de decisão, tendo como resultado uma boa generalização (VAPNIK; CHERVONENKIS, 1971; IVANCIUC, 2007).

Todos os resultados citados neste capítulo que não conseguiram convergir, utilizando a SVM estão ligados a muitas dimensionalidades, ou seja, o algoritmo não consegue encontrar o melhor hiperplano para a classificação. As Tabelas que não convergiram são, 53, 54, 55, 56, 57, 58, 59, 60, 61, 62, 63, 64, 65, 66, 67, 68, 69, 70, 71, 72 e 73.

Sendo assim, o treinamento da SVM consiste em um problema de programação quadrática que é atrativo por encontrar um extremo global da superfície de erro, onde o erro se refere à diferença entre a resposta desejada e a saída da SVM. Outro atrativo é a velocidade dos resultados, superior à modelagem realizada através da retropropagação.

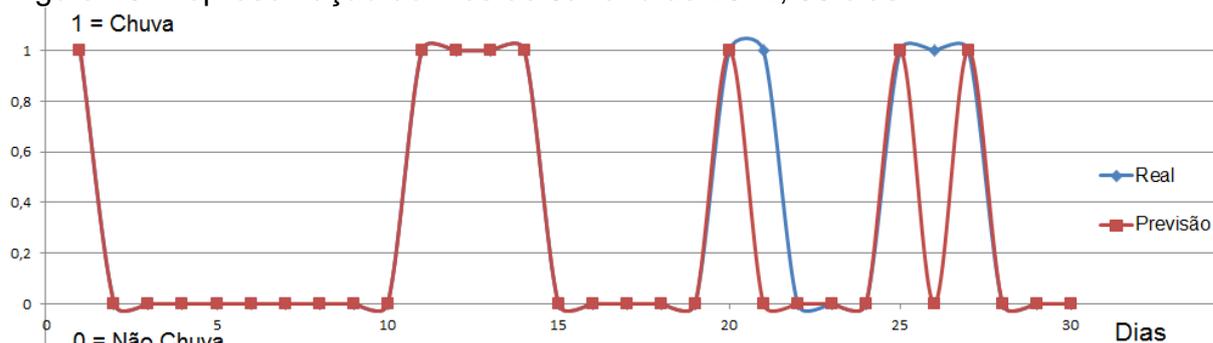
Ao se utilizar o núcleo adequado para a SVM, o cálculo propaga-se automaticamente para todos os parâmetros importantes da rede, relativos ao núcleo escolhido. Em outras palavras, a função de base radial tem uma função gaussiana, e esse método ajusta automaticamente os pesos lineares e níveis de bias sem interferência durante o processo.

Com os resultados representados nas tabelas 47, 48 e 49, este trabalho sugere o modelo SVM (rbf com sigma 0,1) foi o que melhor incorporou os elementos climáticos e apropriou-se do conhecimento do balanço climatológico para encontrar um padrão no comportamento pluvial na cidade de Presidente Prudente. Desta forma, aplicou-se este modelo para o mês de Janeiro de 2012, não incluído nas análises iniciais, a fim de demonstrar a robustez e eficiência da rede neural obtida.

Dentro deste propósito a Figura 15, demonstra os dias do mês de Janeiro, na horizontal (1 a 30 dias), e na vertical o número 1 representa “Chuva” e o número 0 representa “Não Chuva”. Em azul estão apresentados os dados reais e em vermelho os dados preditos através do modelo SVM (rbf sigma 0,1).

Observam-se na Figura 15 as linhas em azul e vermelha, apenas se separam nos dias 21 e 26, ou seja, o modelo diverge apenas dois dias dentro dos 30 dias do mês de Janeiro de 2012.

Figura 15: Representação do mês de Janeiro de 2012, 30 dias.



Fonte: O Autor.

Para facilitar a integração entre o modelo matemático obtido através das redes neurais e o conhecimento geográfico, transferido para a rede neural artificial, a Tabela 74 apresenta os valores dos quatro parâmetros que foram identificados como sendo os principais elementos responsáveis pela chuva.

De um modo geral, os dias que chovem possuem valores mais elevados para a pressão atmosférica, direção do vento, temperatura mínima e umidade relativa do ar, sendo que estes valores estão todos normalizados. Se um desses parâmetros tiver um valor menor, em relação ao conjunto apresentado na Tabela 74, não ocorre a precipitação. Estas observações estão sendo realizadas apenas ao se observar os valores apresentados na Tabela 74, sem a utilização da rede neural treinada, que possui todas as informações armazenadas para efetuar a predição correta.

Nos dias 21 e 25 houve uma predição equivocada do modelo, pois, em sua base de conhecimento foi considerado um dia atípico pelas condições meteorológicas em conjunto com o balanço do ritmo climatológico.

Tabela 74: Valores normalizados dos quatro principais elementos relacionados com a chuva do mês de Janeiro de 2012.

Dias	Pressão Atmosférica	Direção do Vento (0-360)	Temperatura Mínima (°C)	Umidade Relativa do Ar %	Realidade	Predição
1	0,33	0,64	0,83	0,85	CHUVA	CHUVA
2	0,22	0,25	0,80	0,77	NAO_CHUVA	NAO_CHUVA
3	0,33	0,39	0,81	0,70	NAO_CHUVA	NAO_CHUVA
4	0,33	0,50	0,87	0,59	NAO_CHUVA	NAO_CHUVA
5	0,44	0,25	0,91	0,64	NAO_CHUVA	NAO_CHUVA
6	0,33	0,39	0,83	0,71	NAO_CHUVA	NAO_CHUVA
7	0,22	0,50	0,81	0,73	NAO_CHUVA	NAO_CHUVA
8	0,22	0,25	0,80	0,72	NAO_CHUVA	NAO_CHUVA
9	0,44	0,25	0,77	0,71	NAO_CHUVA	NAO_CHUVA
10	0,22	1,00	0,83	0,77	NAO_CHUVA	NAO_CHUVA
11	0,22	1,00	0,75	0,95	CHUVA	CHUVA
12	0,44	1,00	0,74	0,93	CHUVA	CHUVA
13	0,44	1,00	0,77	0,94	CHUVA	CHUVA
14	0,33	1,00	0,78	0,95	CHUVA	CHUVA
15	0,22	0,14	0,85	0,93	NAO_CHUVA	NAO_CHUVA
16	0,33	0,89	0,83	0,77	NAO_CHUVA	NAO_CHUVA
17	0,33	0,14	0,74	0,84	NAO_CHUVA	NAO_CHUVA
18	0,33	0,25	0,76	0,85	NAO_CHUVA	NAO_CHUVA
19	0,33	1,00	0,83	0,79	NAO_CHUVA	NAO_CHUVA
20	0,33	1,00	0,83	0,82	CHUVA	CHUVA
21	0,33	0,39	0,00	0,90	CHUVA	NAO_CHUVA
22	0,44	0,14	0,00	0,77	NAO_CHUVA	NAO_CHUVA
23	0,22	1,00	0,75	0,44	NAO_CHUVA	NAO_CHUVA
24	0,33	0,64	0,82	0,87	NAO_CHUVA	NAO_CHUVA
25	0,33	0,39	0,82	0,91	CHUVA	CHUVA
26	0,33	0,25	0,73	0,81	CHUVA	NAO_CHUVA
27	0,33	0,39	0,63	0,90	CHUVA	CHUVA
28	0,44	0,25	0,69	0,71	NAO_CHUVA	NAO_CHUVA
29	0,44	0,25	0,77	0,59	NAO_CHUVA	NAO_CHUVA
30	0,44	0,39	0,77	0,52	NAO_CHUVA	NAO_CHUVA

Fonte: Estação Meteorológica da UNESP\*, normalizados pelo Autor.

Outra forma de demonstrar esta relação está no sequenciamento da Tabela 75, na qual a letra “C” significa “Chuva” e a letra “N” significa “Não Chuva”, em amarelo são os dias que o modelo não encontrou o padrão, sugerindo outro valor, ou seja, nos dias 21 e 26 de Janeiro de 2012, o modelo §

§ Dados fornecidos pela Estação Meteorológica da UNESP.

indicou valores incorretos com relação à realidade ocorrida, assim nestes dias que houve chuva o modelo apontou que não deveria ocorrer chuva.

Tabela 75: Representação dos dias que choveram e dias que não choveram em Janeiro de 2012.

SVM (rbf)	C	N	N	N	N	N	N	N	N	N	C	C	C	C	N	N	N	N	N	C	N	N	N	N	C	N	C	N	N	N
Realidade	C	N	N	N	N	N	N	N	N	N	C	C	C	C	N	N	N	N	N	C	C	N	N	N	C	C	C	N	N	N
Dias Jan/2012	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30

Fonte: O Autor..

Já a matriz de confusão para o mês de Janeiro de 2012 apresenta-se da seguinte forma, na Tabela a seguir.

Tabela 76: Matriz de confusão representando os 30 dias de Janeiro de 2012.

Classe	Precipitação	Não Precipitação	Total	Erro
Precipitação	8	2	10	20,00%
Não Precipitação	0	20	20	0,00%
kappa(k) 0,824	Total Global		30	
	Sigma = 0,1		Acurácia	93,33%

Fonte: O Autor..

A verificação da matriz de confusão é realizada na diagonal, onde é demonstrado os valores 8 e 20, ou seja, são valores assertivos sugeridos pelo modelo. O valor de acurácia de 93,33%, significando um bom resultado e o coeficiente de Kappa sendo 0,824, que de acordo com Landis e Kock (1977) é um resultado classificado como excelente.

De acordo com Scott (1992), Liu, Yin e Zhang (2012) e Pessoa et al. (2012) relatam que para avaliar a matriz de confusão de outra forma, aplica-se a classificação de Verdadeiro Positivo, Verdadeiro Negativo, Falso Positivo e Falso Negativo para se adquirir instâncias classificadas corretamente ou não para cada classe.

Segundo Theodoridis e Koutroumbas (2006), a matriz de confusão Tabela 75, é construída de tal forma que os elementos da diagonal expressam as instâncias classificadas corretamente e a soma de cada coluna indica o total de instâncias de cada classe.

Tabela 77: Representação do Verdadeiro Positivo, Verdadeiro Negativo, Falso Positivo e Falso Negativo.

	Chove	Não Chove
Positivo	VP 8	FP 20
Negativo	FN 2	VN 0

Fonte: O Autor.

De acordo com Theodoridis e Koutroumbas (2006) e Pessoa et al. (2012), os cálculos são realizados de acordo com as equações a seguir.

$$\text{VerdadeiroPositivo} = \frac{VP}{VP + FN} = \frac{8}{8 + 2} = 0,8 = 80\% \quad \text{Equação 12}$$

$$\text{VerdadeiroNegativo} = \frac{VN}{VN + FP} = \frac{0}{0 + 20} = 0 = 0\% \quad \text{Equação 13}$$

$$\text{FalsoPositivo} = \frac{FP}{VN + FP} = \frac{20}{0 + 20} = 1 = 100\% \quad \text{Equação 14}$$

$$\text{FalsoNegativo} = \frac{FN}{VP + FN} = \frac{2}{8 + 2} = 0,2 = 20\% \quad \text{Equação 15}$$

A Equação 12, de acordo com Theodoridis; Koutroumbas (2006) e Aguiar Pessoa et al. (2012), determina a porcentagem de dias “chuva” classificados como correto para o mês de Janeiro de 2012, ou seja, 80% dos dias chuvosos de Janeiro estão classificados corretamente, ou seja, 28 dias corretos de 30 dias avaliados com 93,33% de acurácia.

A Equação 13 determina que os dias “Não chuva” são classificados com 0% de erro, ou seja, foi classificado 100% correto, na qual é representado pela Equação 14. Na Equação 15 demonstra justamente a porcentagem de erros classificados na Equação 12, ou seja, são classificados 20% de modo incorreto dentro do mês de Janeiro de 2012.

Para comprovar estes cálculos segundo Pessoa et al. (2012) e Theodoridis e Koutroumbas (2006) a soma dos resultados das Equações 12,

13, 14 e 15, representam quantidade de classes, que no caso deste trabalho é igual a 2 representadas por “chuva” e “não chuva”.

Diante destes resultados, é possível afirmar que, para o mês aferido, há 80% de acerto entre os dias 1 e 30 referentes ao mês de Janeiro de 2012, ou seja, o modelo não conseguiu encontrar o padrão de pluviosidade, apenas para dois dias (dia 21 e 26) do mês verificado.

## 6 CONCLUSÕES E TRABALHOS FUTUROS

Os resultados obtidos neste trabalho vieram ao encontro dos objetivos iniciais de se investigar o comportamento das redes neurais propostas, diante do balanço pluviométrico, utilizando dados da estação meteorológica de Presidente Prudente, mais especificamente a estação de número 83716, localizada à latitude -22.12 e longitude -51,38.

Os resultados obtidos foram matematicamente validados através das matrizes de confusões que indicaram o bom poder de identificação dos modelos gerados. Adicionalmente, realizou-se a identificação da chuva para o mês de Janeiro de 2012, tendo como resposta um reconhecimento acerca de 80% de acerto e 93,33% de acurácia.

Os modelos baseados em RNA apresentados neste estudo mostraram-se flexíveis o suficiente para serem aplicados na cidade de Presidente Prudente, na qual a não linearidade das séries de dados tornam-se candidatas ideais para o uso desta técnica, principalmente no que se refere à quantidade de dados e a não continuidade, que são escassos.

A forma de criação dos modelos e os bons resultados obtidos se devem principalmente na preparação dos dados, no treinamento das redes e na variação dos parâmetros internos dos núcleos, que são essenciais para um bom resultado.

Outra característica interessante deste trabalho são os cálculos não lineares que conseguiram delinear os padrões diários de chuva da cidade de Presidente Prudente, identificando assim a precipitação para o próximo instante do dia solicitado. Sabendo-se os valores dos quatro parâmetros utilizados na rede neural, a saber:

- i) característica da variação da pressão atmosférica nas últimas 3 horas;
- ii) direção do vento de 0 a 360 graus;
- iii) temperatura mínima °C e;
- iv) umidade relativa do ar %,

é possível determinar a chuva para o próximo instante, com reais chances de acerto.

Lembrando que a análise analítico-separatista dos parâmetros climáticos citados acima, não possibilita a visualização do fenômeno da precipitação em seus processos reais. Segundo Sorre (1934, apud BOIN, 2000, p. 9), a análise analítico-separatista refere-se a valores extremos e a elementos ocasionais, que apontam para médias aritméticas. Muitas vezes estes dados estão totalmente mascarados e distorcem a realidade. Desta forma, a rede neural artificial atua realmente como um classificador, pois utiliza os parâmetros climáticos em conjunto, reconhecendo o padrão pluvial e simulando o comportamento do balanço climatológico, da mesma maneira muito similar que é realizado pelos geógrafos.

Em síntese este estudo procurou analisar os resultados sob a ótica da matemática e da geografia, utilizando-se de modelos matemáticos não lineares, voltados para o reconhecimento de padrões pluviométricos, considerando as visões diferenciadas existentes entre os ramos da matemática e da geografia. Assim demonstrou-se a alta complexidade em alinhar a visão geográfica do ritmo climatológico com o aprendizado dos modelos matemáticos, ou seja, simular o conhecimento artificial voltado ao balanço climatológico que culmina na chuva.

Como trabalhos futuros, é interessante aprofundar-se nos cálculos estatísticos relacionados as 4 variáveis determinadas neste trabalho: **i)** característica da variação da pressão atmosférica nas últimas 3 horas; **ii)** direção do vento de 0 a 360 graus; **iii)** temperatura mínima °C e; **iv)** umidade relativa do ar %, pois, uma vez estimando estas variáveis para um futuro próximo, e com porcentagem de acurácia alta, esta modelagem matemática apresentada neste trabalho tem a capacidade de determinar a previsão da precipitação pluvial com altos índices de acerto e pontualidade.

Determinando tais dias pontuais, o modelo matemático poderá auxiliar com maior eficácia, nas decisões de aplicação de agrotóxicos, pulverizados em grandes áreas sem afetar a saúde de pequenos agricultores que trabalham na região de Presidente Prudente, além de corroborar para o melhor uso e economia do recurso hídrico que está se extinguindo, nos dias de hoje.

## REFERÊNCIAS

ALENCAR, L. P. et al. Comparação de diferentes métodos de estimativa diária da evapotranspiração de referência para a região de Uberaba. **Revista Brasileira de Ciências Agrárias**, Recife, v. 6, n. 2, p. 337-343, abr.-jun. 2011. Disponível em: <[http://www.agraria.pro.br/sistema/index.php?journal=agraria&page=article&op=view&path%5B%5D=agraria\\_v6i2a1124&path%5B%5D=918](http://www.agraria.pro.br/sistema/index.php?journal=agraria&page=article&op=view&path%5B%5D=agraria_v6i2a1124&path%5B%5D=918)> . Acesso em: 02 jul. 2014.

AKEMI, K.; DIAS, C. L. N. Evaporação, evapotranspiração e evaporação líquida no reservatório de foz do areia. **Revista: Associação Brasileira de Recursos Hídricos**, v. 4, n. 3, p. 29-38, jul.-set. 1999. Disponível em: <[http://www.abrh.org.br/SGCv3/UserFiles/Sumarios/1edb342d9df322abaff93af78ec19742\\_26daded66c90125fa745b2575928572a.pdf](http://www.abrh.org.br/SGCv3/UserFiles/Sumarios/1edb342d9df322abaff93af78ec19742_26daded66c90125fa745b2575928572a.pdf)> . Acesso em: 28 jun. 2014.

ARTERO, A. O. **Inteligência artificial: teoria e prática**. São Paulo: Liv. da Física, 2009.

AYOADE, J. O. **Introdução à climatologia para trópicos**. 12. ed. Rio de Janeiro: Bertrand Brasil, 2007.

AZADI, S.; SEPASKHAH, A. R. Annual precipitation forecast for west, southwest, and south provinces of Iran using artificial neural networks. **Theor Appl. Climatol.**, Vienna, n. 109, p. 175-189, 2012. Disponível em: <<http://link.springer.com/article/10.1007%2Fs00704-011-0575-9>>. Acesso em: 07 jan. 2013.

BARROS, J. R; ZAVATTINI, J. A. Bases conceituais em climatologia geográfica. **Mercator - Revista de Geografia da UFC**, v. 8, n. 16, p. 255 – 261. 2009. Disponível em: <<http://www.mercator.ufc.br/index.php/mercator/article/view/289/235>>. Acesso em: 08 nov. 2014.

BAUM, E. C. On the capabilities of multilayer perceptrons. **Journal of Complexity**, n. 4, p. 193-215, 1988. Disponível em: <<http://www.sciencedirect.com/science/article/pii/0885064X88900209>>. Acesso em: 17 jan. 2013.

BOIN, M. N.; ZAVATTINI, J. A. **Chuvvas e erosões no Oeste Paulista: uma análise climatológica aplicada**. 2000. Tese (Doutorado) - Universidade Estadual Paulista - UNESP, Rio Claro, SP.

BLACHE, P. V. L. **As características próprias da Geografia**. (1982). Disponível em: <[http://sigcursos.tripod.com/CARACTERiSTICAS\\_DA\\_GEOGRAFIA.pdf](http://sigcursos.tripod.com/CARACTERiSTICAS_DA_GEOGRAFIA.pdf)>. Acesso em: 10 Dez. 2015.

BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDEMIR, B. T. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: Livros Técnicos e Científicos, 2000. 262 p.

BRAIDO, L. M. H. et al. **A integração da geomorfologia pedologia e climatologia no processo da produção agrícola: exemplo da Bacia Hidrográfica do Paranapanema III – PR**. Disponível em: <[http://www.dge.uem.br/semana/eixo6/trabalho\\_89.pdf](http://www.dge.uem.br/semana/eixo6/trabalho_89.pdf)>. Acesso em: 12 abr. 2014.

BRYSON, A. E.; HO, Y. **Applied optimal control: optimization, estimation and control**. Washington, DC: Hemisphere, 1975.

CHAPELLE, O. et al. Choosing multiple parameters for support vector machines. **Journal Machine Learning**, v. 46, n. 1-3, p. 131-159. Disponível em: <<http://link.springer.com/content/pdf/10.1023%2FA%3A1012450327387.pdf>>. Acesso em: 15 jul. 2014.

FERREIRA, J. S. Teoria e método em climatologia. **Revista GEONORTE**, v. 1, n. 5, p. 766-773, 2012. Disponível em: <[http://cipgeo.ie.sa.ufg.br/up/195/o/TEORIA\\_E\\_METODO\\_EM\\_CLIMATOLOGIA.pdf](http://cipgeo.ie.sa.ufg.br/up/195/o/TEORIA_E_METODO_EM_CLIMATOLOGIA.pdf)>. Acesso em: 13 nov. 2014.

FLEISS, B. L. **The Measurement of interrater agreement**. [2003?]. Disponível em: <[http://hpm.fk.ugm.ac.id/hpmlama/images/Biostatistik/Tutorial\\_4\\_AS/2-chapter18.pdf](http://hpm.fk.ugm.ac.id/hpmlama/images/Biostatistik/Tutorial_4_AS/2-chapter18.pdf)>. Acesso em: 07 set. 2014.

FLORES, E. F. **Modelagem geográfica: um ensaio metodológico aplicado ao Oeste Paulista**. 2000. Tese (Doutorado) - Universidade Estadual Paulista - UNESP, Rio Claro, SP.

HAYKIN, S. **Neural networks: a comprehensive foundation**. Upper Saddle River: Prentice Hall, 1994.

HAYKIN, S. **Redes neurais, princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001.

IPCC. Painel intergovernamental sobre mudanças climáticas. **Quarto Relatório de Avaliação do IPCC–2007**. Disponível em: <[http://www.ipcc.ch/pdf/assessment-report/ar4/syr/ar4\\_syr.pdf](http://www.ipcc.ch/pdf/assessment-report/ar4/syr/ar4_syr.pdf)>. Acesso em: 12 abr. 2014.

IPCC. Painel intergovernamental sobre mudanças climáticas. **Quinto Relatório de Avaliação do IPCC–2013**. Disponível em: <[http://www.climatechange2013.org/images/report/WG1AR5\\_ALL\\_FINAL.pdf](http://www.climatechange2013.org/images/report/WG1AR5_ALL_FINAL.pdf)>. Acesso em: 12 abr. 2014.

IVANCIUC, O. **Applications of support vector machines in chemistry**. [2007?]. Disponível em: <[http://www.ivanciuc.org/Files/Reprint/Ivanciuc\\_Applications\\_of\\_Support\\_Vector\\_Machines\\_in\\_Chemistry.pdf](http://www.ivanciuc.org/Files/Reprint/Ivanciuc_Applications_of_Support_Vector_Machines_in_Chemistry.pdf)>. Acesso em: 07 set. 2014.

JOLY, C. A. **A Mata Atlântica e o aquecimento global**. 2002. Disponível em: <<http://www.comciencia.br/reportagens/clima/clima15.htm>>. Acesso em: 04 abr. 2014.

KNIME, Analytics Platform, Version 2.9.4. Disponível em: <<http://www.knime.org/downloads/overview>> . Acesso em 05 jan. 2014.

KÖEPPEN, W. **Climatologia**: con un estudio de los climas de la tierra. Buenos Aires: Fondo de Cultura Económica, 1948.

KOVÁCS, Z. H. **Redes neurais artificiais**: fundamentos e aplicações. 2. ed. São Paulo: Acadêmica, 1996.

KULKARNI, S. R.; HARMAN, G. **Statistical learning theory**: a tutorial. 2011. Disponível em: <[http://www.princeton.edu/~kulkarni/Papers/Journals/j077\\_2011\\_KulHar\\_WileyTutorial.pdf](http://www.princeton.edu/~kulkarni/Papers/Journals/j077_2011_KulHar_WileyTutorial.pdf)>. Acesso em: 20 jul. 2014.

LANDIS, J. R.; KOCK, G. G. **The measurement of observer agreement for categorical data**. *Biometrics*, v. 33, p. 159-174, 1977. Disponível em: <<http://www-jstor.org.ez259.periodicos.capes.gov.br/stable/pdfplus/2529310.pdf>>. Acesso em: 08 set. 2014.

LEITE, F. J. **A ocupação do Pontal do Parapanema**. 1981. 244 f. Tese (Livre-Docência) – Instituto de Planejamento e Estudos Ambientais da Universidade Estadual Paulista, Presidente Prudente.

LEMES, M. A. M.; MOURA, A. D. **Fundamentos de dinâmica aplicados à meteorologia e oceanografia**. Ribeirão Preto: Holos, 2002.

LIU, Y.; YIN, Y.; ZHANG, S. Hand Gesture Recognition on HU Moments in Interaction of Virtual Reality. In: INTERNATIONAL CONFERENCE ON INTELLIGENT HUMAN-MACHINE SYSTEM AND CYBERNETICS, 4., Qingdao, 2012. **IEEE Xplore Digital Library**. Disponível em: <<http://ieeexplore.ieee.org/xpl/mostRecentIssue.jsp?punumber=6305330>>. Acesso em: 14 Jan. 2015

MARENCO, J. A. **Mudanças climáticas globais e seus efeitos sobre a biodiversidade**: caracterização do clima atual e definição das alterações climáticas para o território brasileiro ao longo do Século XXI. 2. ed. Brasília: Ministério do Meio Ambiente, Secretaria de Biodiversidade e Florestas, 2007.

MARIN, F. R. et al. **Clima e ambiente**: introdução à climatologia para ciências ambientais. Campinas: Embrapa Informática Agropecuária, 2008.

MANFRON, P. A. et al. **Ambiente agrícola**: livro I. Porto Alegre: Cidadeja, 2013. p. 133.

MONTEIRO, C. A. F. **Clima e excepcionalismo**. Florianópolis: UFSC, 1991.

- MONTEIRO, C. A. F. **Análise rítmica em climatologia**: problemas da atualidade climática em São Paulo e achegas para um programa de trabalho. São Paulo: Instituto de Geografia/USP, 1971. (Série Climatologia, nº1)
- MONTEIRO, C. A. de F.. **A dinâmica climática e as chuvas no Estado de São Paulo**. São Paulo: IGEOG/USP, 1973. 129 p.
- MONTEIRO, J. E. B. A. **Agrometeorologia dos cultivos**: o fator meteorológico na produção agrícola. Brasília: Instituto Nacional de Meteorologia, 2009.
- PASSOS, M. M. Unidades básicas e dinâmica atual da paisagem no Pontal do Paranapanema. **Revista Geografia**, v. 10, p. 51-73, 1991.
- PESSOA, A. S. A. et al. Mineração de dados meteorológicos para previsão de eventos severos. **Revista Brasileira de Meteorologia**, v. 27, n. 1, 61 - 74, 2012. Disponível em: <<http://www.scielo.br/pdf/rbmet/v27n1/a07v27n1>>. Acesso em 21 Jan. 2015
- PÉDELABORDE, P. **Introduction a l'étude scientifique du clima**. Tradução de João Afonso Zavattini. Paris: Société d'Édition d'Enseignement Supérieur, 1970. p. 5-31.
- PEREIRA, A. R.; NOVA, N. A. V.; SEDIYAMA, G. C. **Evapo(transpi)ração**. Piracicaba: FEALQ, 1997. 183 p.
- PRIMAVESI, O.; ARZEB C.; SANTOS, P. M. **Aquecimento global e mudanças climáticas**: uma visão integrada tropical. São Carlos: Embrapa Pecuária Sudeste, 2007.
- ROLIM, G. D. S. et al. Classificação climática de Köppen e de Thornthwaite e sua aplicabilidade na determinação de zonas agroclimáticas para o estado de São Paulo. **Bragantia**, v. 66, p. 711-720, 2007. Disponível em: <<http://www.acervodigital.unesp.br/bitstream/unesp/135692/1/S0006-87052007000400022.pdf>>. Acesso em: 19 jun. 2014.
- RUBENS, L. V.; ADIL, R. A. **Meteorologia básica e aplicações**. Viçosa: UFV, 2000. 448 p.
- SANT'ANNA NETO, J. L. Decálogo da climatologia do sudeste brasileiro. **Revista Brasileira de Climatologia**, v. 1, n. 1, 2005. Disponível em: <<http://ojs.c3sl.ufpr.br/ojs/index.php/revistaabclima/article/view/25232/16936>>. Acesso em: 05 jul. 2014.
- SANT'ANNA NETO, J. L. A análise geográfica do clima: produção de conhecimento e considerações sobre o ensino. **Revista Geografia**, v. 1, n. 2, p. 321-328, jul/dez. 2002. Disponível em: <<http://www.uel.br/revistas/uel/index.php/geografia/article/viewFile/6734/12407>>. Acesso em: 15 nov. 2014.
- SASAKI, J. E. **Development and validation of accelerometer-based activity classification algorithms for older adults**: a machine learning approach.

2014. 199 f. Tese (Doctor of Philosophy) – Department of Kinesiology, University of Massachusetts, Amherst.

SANTOS, L. B. **O papel dos países em desenvolvimento na efetividade do regime internacional de mudanças climáticas:** adoção de metas de redução de gases de efeito estufa. 2011. Disponível em: <<http://periodicos.ufes.br/SNPG/CS/article/view/1520/1111>>. Acesso em: 14 ago. 2014.

SCOTT, D. W. **Multivariate density estimation:** theory, practice, and visualization. New York: John Wiley and Sons, 1992. 376 p.

SCHÖLKOPF, B.; DECOSTE, D. Training invariant support vector Machines. **Machine Learning**, v. 46, p. 161–190, 2002. Disponível em: <<http://link.springer.com/content/pdf/10.1023%2FA%3A1012454411458.pdf>> . Acesso em: 10 jul. 2014.

SORRE, M. Objeto e método da climatologia. **Revista do Departamento de Geografia**, v. 18, p. 89-94, 2006. Disponível em: <[http://www.geografia.fflch.usp.br/publicacoes/RDG/RDG\\_18/RDG18\\_089\\_094.pdf](http://www.geografia.fflch.usp.br/publicacoes/RDG/RDG_18/RDG18_089_094.pdf)>. Acesso em: 09 nov. 2014.

SOUSA, I. F. et al. Evapotranspiração de referência nos perímetros irrigados do estado de Sergipe. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, n. 6, 2010. Disponível em: <[http://www.scielo.br/scielo.php?pid=S1415-43662010000600010&script=sci\\_arttext](http://www.scielo.br/scielo.php?pid=S1415-43662010000600010&script=sci_arttext)>. Acesso em: 02 jul. 2014.

SOUZA, D. M., & NERY, J. T. **Parâmetros climáticos de Ourinhos, Estado de São Paulo.** doi: 10.4025/actasci humansoc. v33i1. 10043. Acta Scientiarum. Human and Social Sciences, 33(1), 107-115, 2011. Disponível em: <<http://www.ourinhos.unesp.br/Home/Pesquisa/GruposdeEstudo/Clima/Simposios/110.pdf>>. Acesso em: 15 Ago. 2014.

SPIRO, T. G.; STIGLIANI, W. M. **Química ambiental.** São Paulo: Pearson Prentice Hall, 2008.

TAFNER, M. A.; XEREZ, M. R. F.; ILSON, W. **Redes neurais artificiais:** introdução e princípios de neurocomputação. Blumenau: Universidade Regional de Blumenau, 1996.

TARIFA, J. R. **A análise topo e microclimática e o trabalho de campo: o caso de São José dos Campos.** Climatologia, São Paulo, vol. 13, p.1-25, 1981.

TARIFA, J. R.; AZEVEDO, T. R. **O ritmo e a prática de estudos dos climas de São Paulo (1970-2000).** Os climas na cidade de São Paulo: teoria e prática. São Paulo: Pró-Reitoria de Cultura e Extensão. Universidade de São Paulo: Laboratório de Climatologia. Faculdade de Filosofia, Letras e Ciências Humanas. Universidade de São Paulo, Cap. 1. p. 11-33. (Geosp-Coleção o Novos Caminhos, 4), 2001.

THEODORIDIS, S.; KOUTROUMBAS, K. **Pattern recognition**. San Diego-CA: Academic Press, 2006. 837p.

TUBELIS, A.; NASCIMENTO, F. J. L. **Meteorologia descritiva: fundamentos e aplicações brasileiras**. Botucatu: UNESP, Faculdade de Ciências Agrônômicas, 1937.

VAPNIK, V. N.; CHERVONENKIS, A. Y. On the uniform convergence of relative frequencies of events to their probabilities. **Theory probability application**, v. 16, n. 2, p. 264-280, 1971. Disponível em: <<http://epubs.siam.org/doi/pdf/10.1137/1116025>>. Acesso em: 17 jul. 2014.

VAPNIK, V. N. An overview of statistical learning theory. **IEEE Transactions on Neural Networks**, n.10, p. 988–999, 1999. Disponível em:<[http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=788640&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs\\_all.jsp%3Farnumber%3D788640](http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=788640&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs_all.jsp%3Farnumber%3D788640)>. Acesso em: 17 jul. 2014.

VELOSO, G. et al. Estimativa de evapotranspiração de referência para o município de Fernandes Pinheiro – PR. Unioeste - Projeto Saber. **Acta Iguazu**, Cascavel, v. 1, n. 1, p. 15-22, 2012. Disponível em: <<http://e-revista.unioeste.br/index.php/actaiguazu/issue/view/460>>. Acesso em: 02 jul. 2014.

VIANELLO, R. L.; ALVES, A. R. **Meteorologia básica e aplicações**. Viçosa: UFV, 2000. 448 p.

ZAVATTINI, J. A. **Estudos do clima no Brasil**. Campinas: Alínea, 2004.

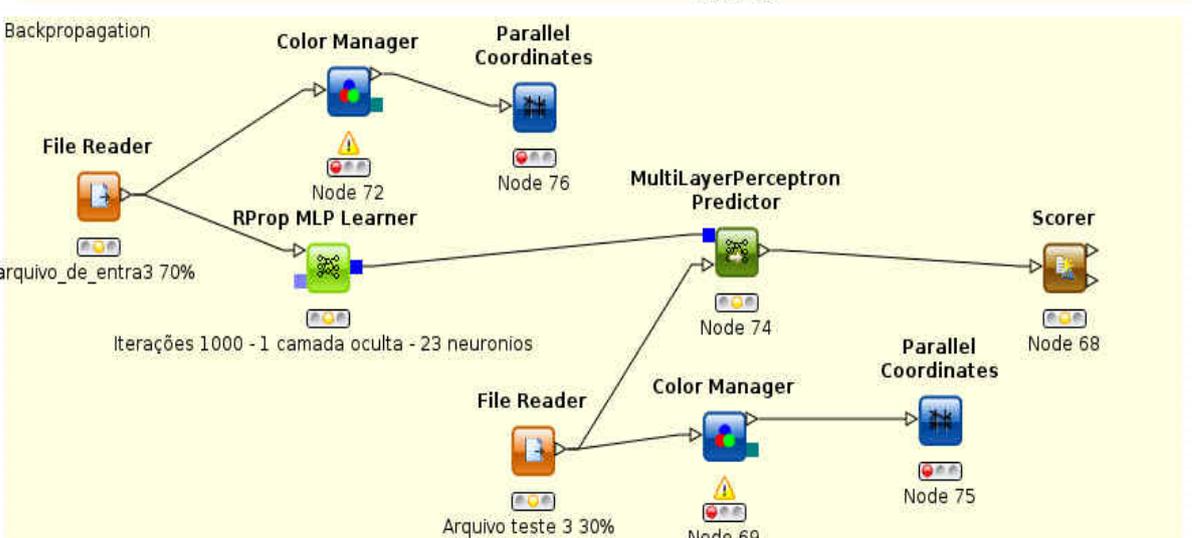
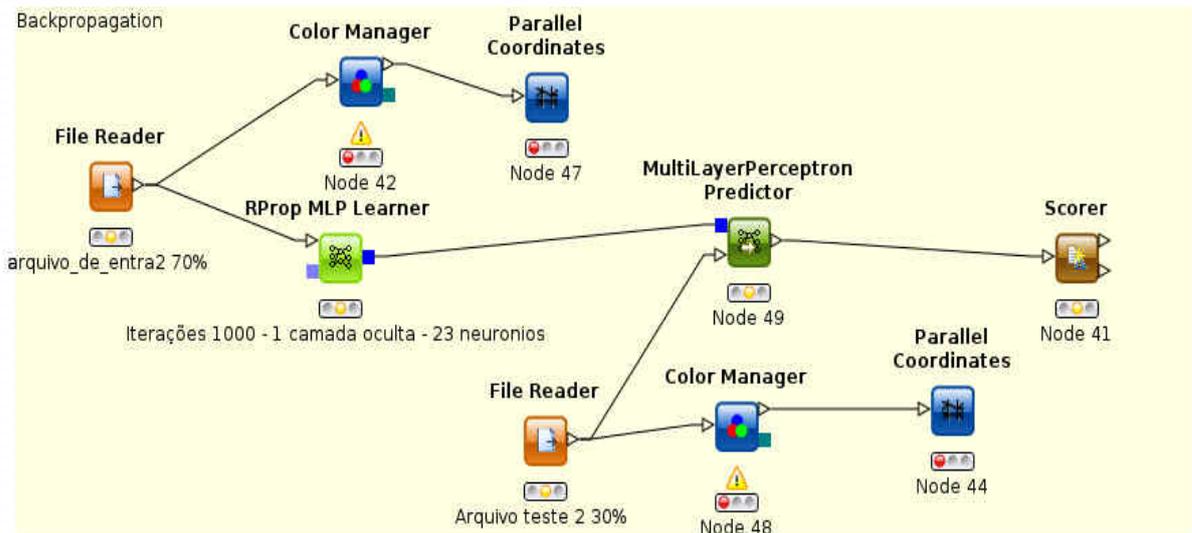
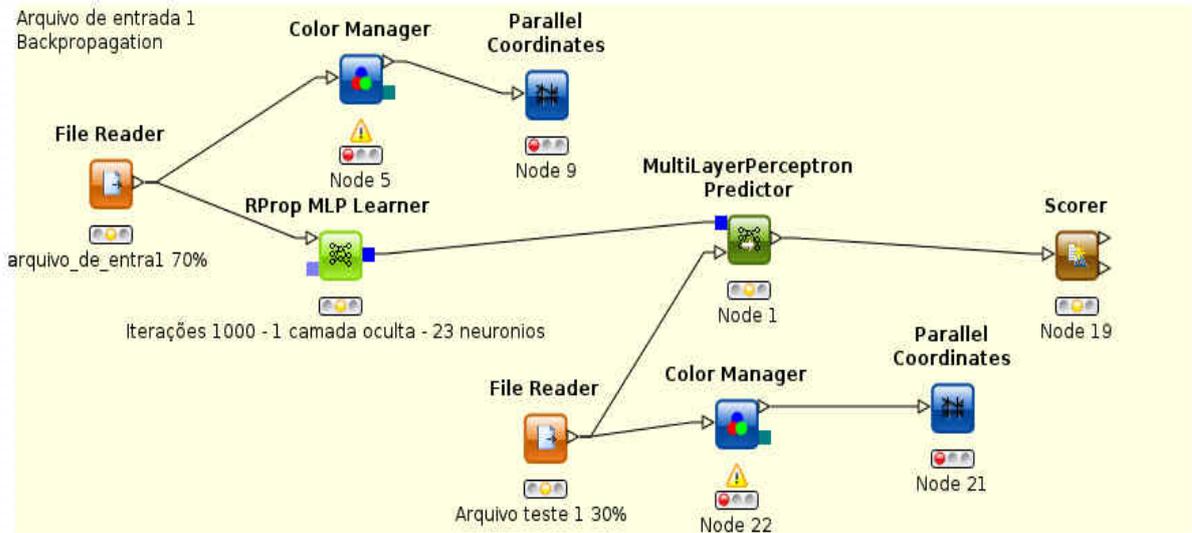
ZAVATTINI, J. A.; BOIN, M. N. **Climatologia geográfica: teoria e prática de pesquisa**. Campinas: Alínea, 2013.

WERBOS, P. J. Backpropagation through time: what it does and how to do it. **Proceedings of the IEEE**, v. 78, n. 10, out. 1990. Disponível em: <[http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=58337&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs\\_all.jsp%3Farnumber%3D58337](http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=58337&url=http%3A%2F%2Fieeexplore.ieee.org%2Fxppls%2Fabs_all.jsp%3Farnumber%3D58337)>. Acesso em: 05 maio 2013.

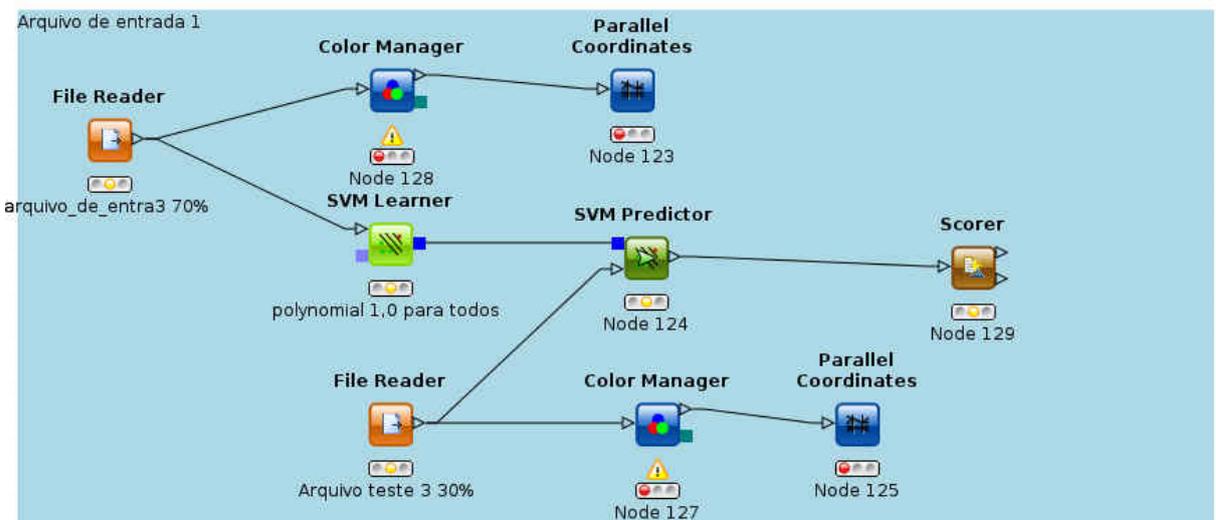
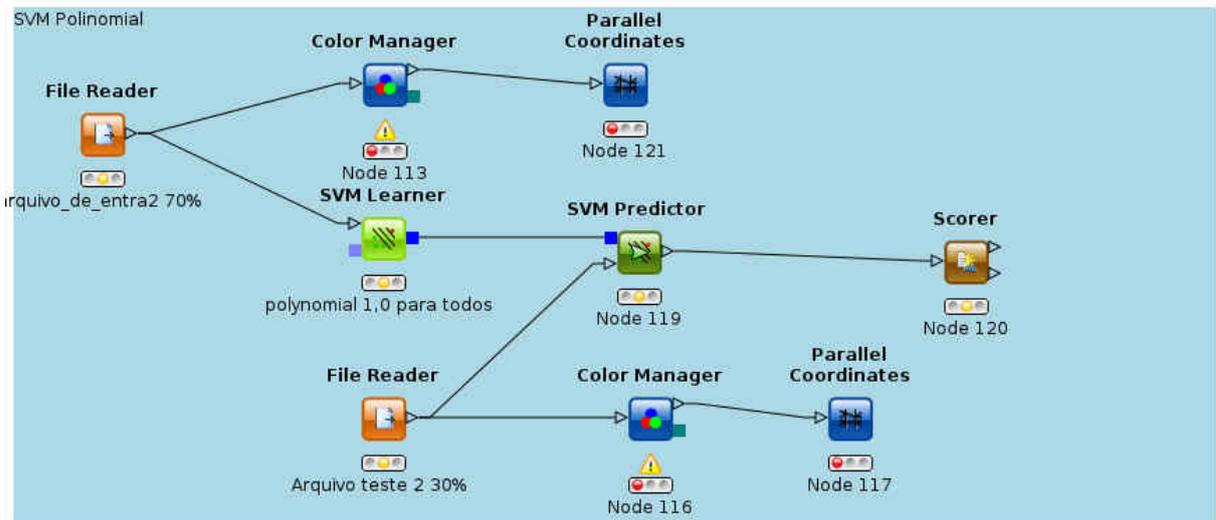
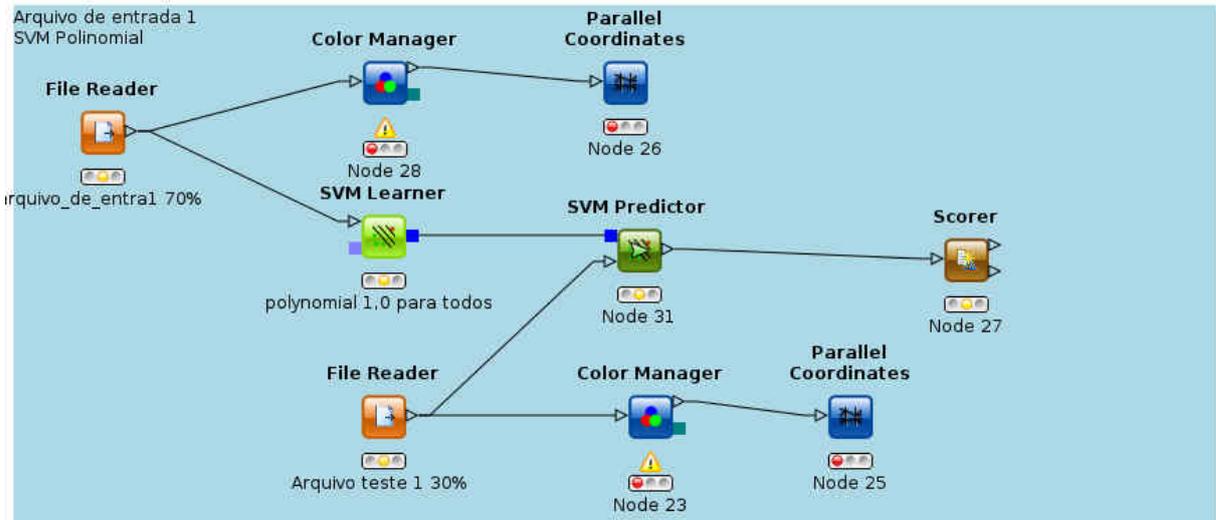
## **APÊNDICE A**

Modelos criados utilizando o software Knime versão 2.9.4, praticamente todos os modelos seguem os mesmos grafos, mudando apenas as configurações do aprendizado de acordo com o citado na Tabela 3.

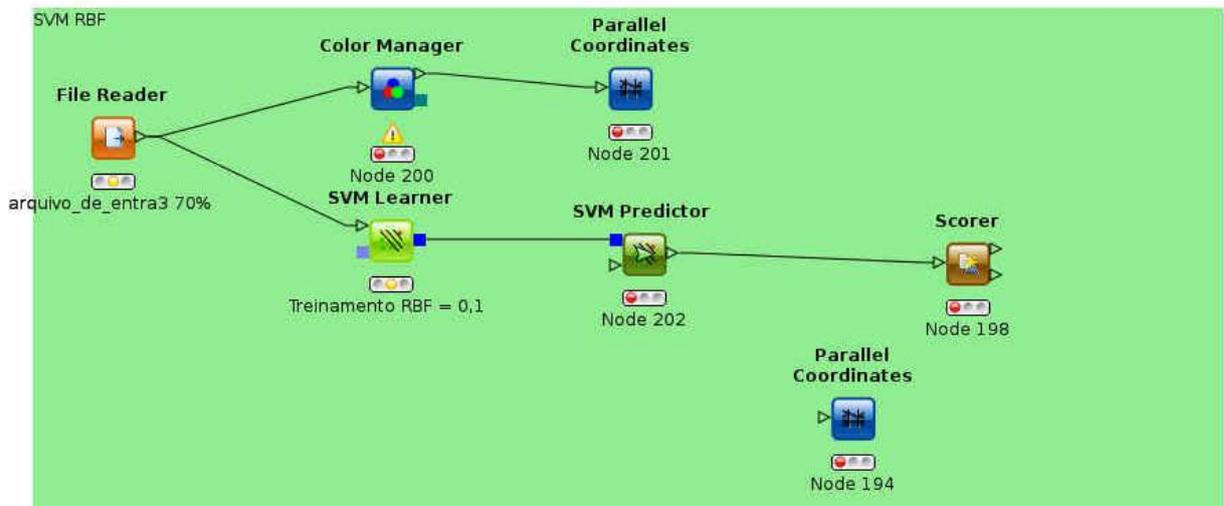
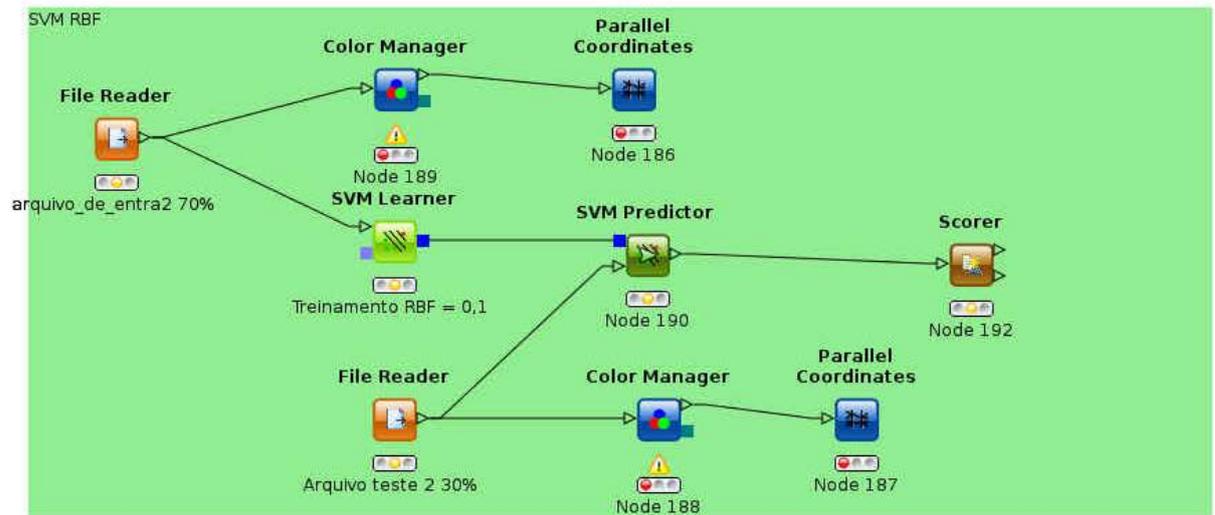
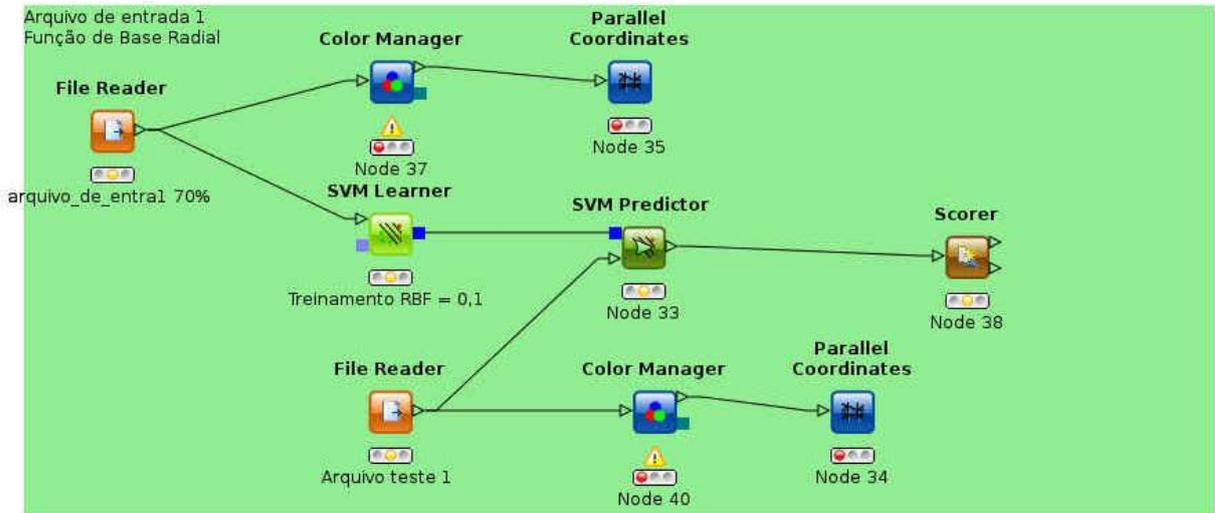
1 CAMADA OCULTA BACKPROPAGATION



SVM POLINOMIAL - parametros todos 1,0



SVM RBF - Treinamento RBF = 0,1



SVM Sigmoide = Kappa 0,1 e Delta 0,5

