

ANDERSON FRANCISCO DA SILVA

**PREVISÃO DA EVAPOTRANSPIRAÇÃO DE REFERÊNCIA
UTILIZANDO REDES NEURAIS**

Tese apresentada à
Universidade Federal de Viçosa,
como parte das exigências do
Programa de Pós-Graduação
em Engenharia Agrícola, para
obtenção do título de “Magister
Scientiae”.

**VIÇOSA
MINAS GERAIS - BRASIL
2002**

ANDERSON FRANCISCO DA SILVA

**PREVISÃO DA EVAPOTRANSPIRAÇÃO DE REFERÊNCIA
UTILIZANDO REDES NEURAIS**

Tese apresentada à
Universidade Federal de Viçosa,
como parte das exigências do
Programa de Pós-Graduação
em Engenharia Agrícola, para
obtenção do título de “Magister
Scientiae”.

Aprovada: 30 de agosto de 2002.

Prof. Brauliro Gonçalves Leal
(Conselheiro)

Prof. Gilberto C. Sedyama
(Conselheiro)

Prof. Aristides Ribeiro

Prof. José Maria N. da Costa

Prof. Luiz Cláudio Costa
(Orientador)

Ao Onisciente que tudo prevê.

AGRADECIMENTO

Ao Departamento de Engenharia Agrícola da Universidade Federal de Viçosa pela oportunidade da realização deste curso.

Aos professores Luiz Cláudio Costa, Antônio de Pádua Braga e Brauliro Gonçalves Leal, pelo especial apoio na criação da idéia, no embasamento teórico e na análise dos resultados deste trabalho.

À Edna, quem salvou minha vida mais vezes que meu revólver pode contar.

Aos amigos Paulo Márcio e Alessandro por gerarmos frutos imperecíveis.

À equipe da Cientec: Ana Marcelina, Gustavo, Daiane, Jaqueline, Gleison, Alisson, Marcelo e Valdoni pela alegria do labor útil.

Aos amigos Erisvaldo Juvêncio, Orlando Júnior, Camilo Augusto e Paulo Fernando por termos construído uma república chamada lar.

Aos meus pais, D. Elza, Sr. João, por nunca me deixarem empolgar pelo desânimo.

Aos manos e manas: Haga, Consola, Rê, Li, João Filho, Meri, Gi, Lila, Binha e Duda, pela honra de tão nobre companhia.

À Melisa Fernandes Maia pelos infindos abraços luminosos.

BIOGRAFIA

ANDERSON FRANCISCO DA SILVA, filho de Elza Bernardina da Silva e João Francisco da Silva, nasceu em São Geraldo, Minas Gerais, ao dia 23 de dezembro de 1974.

Em 1990 foi aprovado no exame de seleção do Coluni, terminado o segundo grau em 1992.

Em 1993 ingressou na Universidade Federal de Viçosa, no curso de Informática, hoje Ciência da Computação, tendo concluído o curso em janeiro de 1997.

Em abril de 1999, iniciou o curso de Mestrado em Engenharia Agrícola nesta universidade, submetendo-se à defesa de tese em agosto de 2002.

ÍNDICE

RESUMO.....	VIII
ABSTRACT.....	IX
INTRODUÇÃO.....	1
REVISÃO DE LITERATURA.....	6
1.1. EVAPOTRANSPIRAÇÃO	6
1.2. NEURÔNIOS.....	7
1.2.1. <i>Neurônio Biológico</i>	7
1.2.2. <i>Neurônio Artificial</i>	8
1.3. FUNÇÃO DE ATIVAÇÃO	9
1.4. REDES NEURAIIS	10
1.5. APRENDIZAGEM	11
1.6. REDE NEURAL MULTIVARIADA	15
1.7. APLICAÇÕES	15
1.8. ALGORITMOS HÍBRIDOS	17
1.9. ERROS DE PREDIÇÃO.....	17
2. MATERIAIS E MÉTODOS	20
2.1. DADOS CLIMÁTICOS	20

2.2.	PROGRAMA COMPUTACIONAL.....	21
2.3.	REDE NEURAL ORIENTADA A OBJETOS.....	23
2.4.	SOBRE-ADEQUAÇÃO.....	24
2.5.	FUNÇÃO DE ATIVAÇÃO	24
2.6.	INICIALIZAÇÃO DOS PESOS.....	25
2.7.	NÚMERO IDEAL DE ANOS.....	25
2.8.	PARÂMETROS DAS REDES NEURAIIS	26
2.9.	TAXA DE APRENDIZAGEM, FATOR MOMENTUM E NÚMERO DE ÉPOCAS.....	27
2.10.	NÚMERO DE NEURÔNIOS.....	28
2.11.	REDES DE MÚLTIPLAS CAMADAS.....	29
2.12.	REDES MULTIVARIADAS.....	29
2.13.	ERROS DE PREDIÇÃO.....	31
3.	RESULTADOS E DISCUSSÃO	32
3.1.	EQUIPAMENTO	32
3.2.	SIMULAÇÃO 01.....	32
3.3.	SIMULAÇÃO 02.....	33
3.4.	SIMULAÇÃO 03.....	39
3.5.	SIMULAÇÃO 04.....	43
3.6.	SIMULAÇÃO 05.....	44
4.	CONCLUSÕES E SUGESTÕES.....	46
4.1.	CONCLUSÕES	46
4.2.	SUGESTÕES	47
5.	REFERÊNCIAS BIBLIOGRÁFICAS	50

RESUMO

FRANCISCO SILVA, Anderson, M. S., Universidade Federal de Viçosa, agosto de 2002. **Previsão da Evapotranspiração de Referência Utilizando Redes Neurais..** Orientador: Luiz Cláudio Costa. Conselheiros: Brauliro Gonçalves Leal e Gilberto C. Sedyama.

Este trabalho consta de uma investigação acerca da aplicabilidade das redes neurais na previsão da evapotranspiração de referência. As redes neurais como modelo de reconhecimento de padrão teriam a capacidade de entender o comportamento do clima local, podendo, a partir dos dados climáticos do passado próximo inferir sobre seu comportamento futuro. As melhores previsões obtidas promoveram um erro padrão de estimativa de 0,8mm e um erro percentual relativo médio de 20% para valores da evapotranspiração. A utilização de mais 10 anos no aprendizado das redes mostrou-se irrelevante. O valor 0,01 para a taxa de aprendizagem e para o fator momentum promoveu a obtenção do menor erro em um menor número de épocas. A inclusão de camadas intermediárias ou o aumento do número de seus neurônios não favoreceu melhores ajustes. O aumento do número dias de previsão diminuiu a precisão dos resultados gerando um erro médio de 1mm por dia para períodos de até 10 dias. A utilização das variáveis climáticas ao invés da evapotranspiração calculada não promoveu melhorias dos resultados. O presente inspira estudos da utilização das redes neurais neste e em outros campos da engenharia agrícola.

ABSTRACT

FRANCISCO SILVA, Anderson, M. S., Universidade Federal de Viçosa, August, 2002. **Predition of the Reference Evapotranspiration Utilizing Neural Networks.** Adviser: Luiz Cláudio Costa. Committee members: Braurilo Gonçalves Leal and Gilberto C. Sedyama.

This report is on an investigation about the neural networks applicability at prediction of the reference evapotranspiration. The neural networks, as standard recognition model, would have the capacity of understanding the climate behavior, being able to, starting by climate data of the near past, infer about their future behavior. The best predictions obtained promote a standard square error around 0.8mm and a perceptual error around 20% to evapotranspiration values. The use of more than 10 years in learning phase is shown unimportant. The value 0.01 to the learning rate and to momentum factor promoted the smallest error on smallest number of epochs. The inclusion of the intermediaries layers or the increase of the number of their neurons did not favor better adjusts. The increase of the prediction days decreased the accuracy of the results produces standard errors of 1mm by day to periods until 10 days. The use of climate variables in place of the calculated evapotranspirations did not promote better results. The present inspire studies of the use of the neural networks in this and others fields of the agricultural engineer.

INTRODUÇÃO

A atualidade assiste atenta à globalização da economia mundial, com empresas competindo entre si, visando oferecer melhores produtos e serviços a preços competitivos, em um mercado onde uma multiplicidade de diferentes recursos é considerada (NEVES e CORTEZ, 1997). A sobrevivência neste mercado depende, em grande parte, da capacidade de abstrair cenários futuros, antevendo possíveis problemas e inferindo sobre suas soluções.

VEMURI e ROGERS (1994) sugerem que a predicabilidade é peça fundamental para uma moderna visão científica da natureza. Segundo DINIZ et. al. (1998), a essência da previsão constitui-se da observação do resultado de fenômenos passados para antecipar o seu comportamento futuro. Neste sentido, modelos de previsão têm sido desenvolvidos sobre robustos pilares da matemática, utilizando registros históricos de determinados fenômenos na predição de suas futuras ocorrências.

Algumas atividades, com a agricultura, devido sua suscetibilidade às intempéries, carecem, para não se extremamente totalmente vulneráveis às oscilações climáticas, de métodos que possam realizar com aceitável grau de incerteza a previsão de variáveis úteis.

O crescimento populacional tem pressionado engenheiros, técnicos e cientistas de uma forma geral, a estudar e aplicar tecnologias que venham a aumentar substancialmente a produção de alimentos no planeta. A irrigação vem

contribuindo de forma decisiva nesse processo, como mostrado na Tabela 1. No princípio do século, estima-se que a área total irrigada mundial estava em torno de 40 milhões de hectares. Em 1950, esse valor se elevou para 160 milhões de hectares, e em 1990 já compunham 275 milhões de hectares.

Tabela 1 – Produtividade Média de Culturas Irrigadas e Não Irrigadas¹

Cultura	Produtividade Média (ton/ha)	
	Irrigada	Não Irrigada
Arroz	4,0 - 8,0	1,0 - 2,0
Batata	15,0 - 20,0	8,0 - 12,0
Cana-de-açúcar	120,0 - 150,0	30,0 - 60,0
Cebola	11,0 - 13,0	5,0 - 7,0
Feijão	2,0 - 2,2	0,6 - 1,2
Laranja	8 a 10 caixas/planta	1,7 caixas/planta
Melão	25,0 - 30,0	8,0 - 12,0
Milho	4,0 - 6,0	2,0 - 3,0
Soja	2,5 - 3,0	1,2 - 1,5
Tomate	40,0 - 60,0	12,0 - 14,0
Trigo	4,0 - 6,0	1,5 - 2,0

A agricultura irrigada é o mais representativo uso consuntivo de água, sendo responsável, em média, por 63,5% do consumo mundial de água, enquanto o consumo humano representa apenas 7,9% desse total. Por outro lado, estima-se em 40% a parcela de água que sai dos mananciais e não chegam a seu destino, no caso do consumo urbano, em decorrência de vazamentos nos reservatórios e nas redes de distribuição. Na irrigação esta perda é estimada em 45%, aqui, em consequência do uso de métodos pouco eficientes de manejo (CHRISTOFIDIS, 1997). A necessidade dos múltiplos usuários da água, como por exemplo, os humanos e a indústria, contribuem na exigência de seu uso racional na irrigação.

¹ Fonte: <http://www.agr.unicamp.br/reenge/irrigacao/fa709INTR.htm>

O Brasil possui uma superfície territorial de 851 milhões de ha, com 380 milhões de hectares potencialmente agricultáveis. Atualmente, em torno de 26% do território brasileiro está sendo explorado, ou seja, cerca de 200 milhões de hectares dos quais 50 milhões com agricultura e 150 milhões com pecuária. Segundo PRONI (1987) entre todos os países do mundo, o Brasil detém o segundo potencial de áreas irrigadas: são 55 milhões de hectares, sendo 30 milhões de terras baixas de várzeas e 25 milhões de terras altas. Atualmente existem 3 milhões de hectares irrigados no país, o que representa 5,5% da área potencialmente irrigável.

A Agência Nacional de Águas – ANA, criada com o objetivo de implementar a outorga, a cobrança e a fiscalização do uso da água, garantindo sua disponibilidade no futuro, impõe a busca de soluções que minimizem os custos de produção de culturas irrigadas, viabilizando, por meio da qualidade e do preço dos produtos, a competitividade das propriedades que utilizam ou pretendem utilizar sistemas de irrigação.

A determinação do volume de água necessário às culturas constitui informação imprescindível ao planejamento e manejo de qualquer sistema de irrigação (SALASSIER, 1995). A lâmina de água que deixa o solo num dado período de tempo devido à evaporação diretamente da superfície do solo e à transpiração da cultura é conhecida como evapotranspiração.

Segundo MELLO (1998), o termo evapotranspiração potencial (ETp) é usado para descrever o nível potencial ou máximo de evapotranspiração para uma cultura, resultante de condições não limitantes de água. A definição da ETp depende das condições do sistema de cultura pode se tornar confusa, dessa forma o termo evapotranspiração de referência tornou-se mais comum e mais adequado à utilização prática.

A evapotranspiração de referência (ETo) é usualmente associada à evapotranspiração que se processa em um solo coberto totalmente por uma vegetação rasteira, com crescimento ativo e uniforme, sem deficiência hídrica e com altura entre 8 e 15cm (DOORENBOS e PRUITT, 1977), tornando-se assim um fator dependente exclusivamente do clima.

KUMAR et al. (2002) afirmam que evapotranspiração de referência é um dos principais componentes do ciclo hidrológico e a precisão na sua estimativa é de suprema importância para muitos estudos tais como balanço hidrológico de água, projetos e manejo de sistemas de irrigação, simulação de produtividade de culturas e planejamento e gerenciamento de recursos hídricos.

Uma grande economia de água e dos recursos associados, como energia elétrica e mão-de-obra, pode ser obtida realizando-se boas previsões da evapotranspiração de referência – ETo, fundamental ao manejo de sistemas de irrigação. A partir dos dados de evapotranspiração, desprezando-se as eventuais precipitações, torna-se possível realizar uma simulação do balanço hídrico da cultura, isto é, a estimar a umidade do solo em um dado tempo futuro, o que permite planejar as irrigações necessárias, construindo um cenário do manejo que sirva de base para tomadas de decisão.

O tamanho da série de monitoramento de variáveis climáticas, sua natureza temporal e a qualidade dos dados são características bastante adequadas à utilização de métodos de reconhecimento de padrões voltados à previsão (SOARES e SOARES, 1999). BRAGA et al. (2000) afirmam que as redes neurais são aptas a resolver problemas de cunho geral, tais como aproximação, classificação, categorização, predição, etc., sendo assim uma ferramenta ideal à previsão climatológica.

As redes neurais podendo ser vistas como um modelo matemático de reconhecimento de padrão, são ferramentas adequadas à previsão climática. Segundo NEVES e CORTEZ (1997), as redes neurais têm a capacidade de extrair dependências implícitas entre os dados, mesmo quando não existe entendimento da natureza dessas dependências ou quando os dados apresentam um forte componente de ruído.

Este trabalho objetiva investigar a aplicabilidade das redes neurais à previsão da evapotranspiração de referência. Tais previsões constituiriam uma ferramenta extremamente útil, no que concerne às tomadas de decisão por parte do produtor, durante o processo do manejo da irrigação.

Como objetivo secundário, espera-se a criação do software Smart Climate capaz de realizar a aprendizagem de redes neurais, utilizando diferentes informações de entrada gravadas em arquivos no formato texto. As redes neurais criadas neste programa poderão ser gravadas em arquivos digitais, disponibilizando o conhecimento adquirido para posterior utilização. Este software será divulgado na Internet juntamente com seu código fonte, de modo que possa ser utilizado, estudado e aperfeiçoado por pesquisadores interessados no assunto.

REVISÃO DE LITERATURA

1.1. EVAPOTRANSPIRAÇÃO

A combinação de dois processos distintos por meio dos quais ocorre a perda de água, de um lado pela superfície do solo devido à evaporação e de outro pela cultura por meio da transpiração, é referida como evapotranspiração (ET) (FAO56, 1998).

A equação de Penman-Monteith é uma representação bem próxima e simples dos fatores físicos e fisiológicos que governam o processo da evapotranspiração (FAO56, 1998). É descrita pela equação abaixo:

$$ET_o = \frac{0,408\Delta(Rn - G) + g \frac{900}{T + 273} U_2 (es - ea)}{\Delta + g(1 + 0,34U_2)}$$

Equação 1 - Equação de Penman-Monteith

em que:

ET _o	evapotranspiração de referência (grama)	mm d ⁻¹
Rn	saldo de radiação na superfície da cultura	MJ m ⁻² d ⁻¹

G	fluxo de calor no solo	MJ m ⁻² d ⁻¹
T	temperatura média diária	°C
U2	velocidade do vento à 2m de altura	m s ⁻¹
es	pressão de vapor de saturação	kPa
ea	pressão de vapor	kPa
es-ea	déficit da pressão de vapor de saturação	kPa
Δ	declividade da curva de pressão de vapor	kPa °C ⁻¹
γ	constante psicrométrica	kPa °C ⁻¹

KUMAR et al. (2002) estudaram a aplicabilidade das redes neurais na estimativa da evapotranspiração de referência. Comparando os resultados obtidos com dados medidos utilizando-se lisímetro e com valores calculados pela equação Equação 1, concluíram que as redes neurais são capazes de estimar a ETo melhor que o método convencional de Penman-Monteith.

1.2. NEURÔNIOS

1.2.1. Neurônio Biológico

Os neurônios podem ser divididos em três seções: o corpo celular, os dendritos e o axônio, desempenhando, cada uma delas, funções específicas, porém complementares (BRAGA et al. 2000). A função dos dendritos é captar informações provenientes do meio externo ou de outros neurônios e conduzi-las ao corpo celular. O corpo celular reúne as diferentes informações fornecidas pelos dendritos, e após processá-las gera um sinal constante que é conduzido por toda extensão do axônio. Os dendritos de outros neurônios que estiverem conectados a este axônio perceberão o sinal emitido. O ponto de contato entre a terminação axônica de um neurônio e o dendrito de outro é chamada de *Sinapse*, do grego *synapsis*, “ação de juntar”.

A Figura 1 - Neurônio Biológico é uma foto de neurônios proveniente de microscópio eletrônico de esquadramento (scanning). O par de neurônios mais em foco forma sinapses elétricas.




Figura 1 - Neurônio Biológico²

1.2.2. Neurônio Artificial

O primeiro modelo matemático de um neurônio biológico foi desenvolvido pelo psiquiatra e neuroanatomista Warren McCulloch e pelo matemático Walter Pitts em 1943. O neurônio foi representado n terminais de entrada (x_1, x_2, \dots, x_n) que representavam os dendritos e apenas um terminal de saída, o axônio.

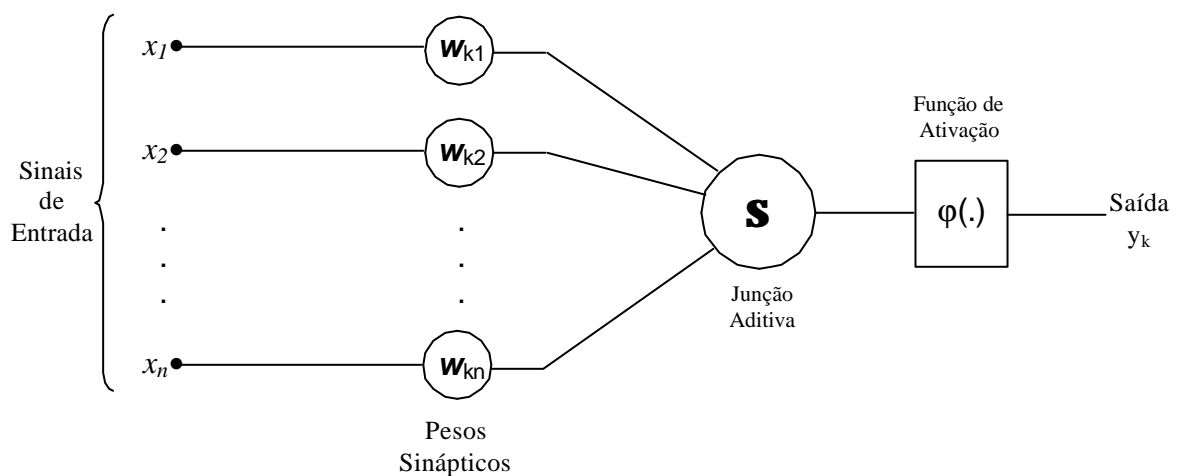


Figura 2 - Neurônio Artificial

² Foto Robert Berdan: <http://www.scienceandart.org/photography/Originals/Npair.html>

1.3. FUNÇÃO DE ATIVAÇÃO

A função de ativação, ou função restritiva, limita o intervalo permissível de amplitude do sinal de saída dos neurônios. ENSLEY e NELSON (1992) sugeriram algumas funções de ativação contínuas e diferenciáveis mostradas na tabela a seguir.

Funções de Ativação	Fórmula	Intervalo
Seno	$f(x) = Sen(x)$	[-1,+1]
Co-seno	$f(x) = Cos(x)$	[-1,+1]
Gaussiana	$f(x) = e^{-(x^2/2)}$	[0,1]
Gaussiana Negativa	$f(x) = -e^{-(x^2/2)}$	[-1,0]
Secante Hiperbólica	$f(x) = Sech(x)$	[0,1]
Sigmóide Logística	$f(x) = \frac{1}{1+e^{-x}}$	[0,1]
Sigmóide Logística Parametrizada	$f(x) = \frac{1}{1+e^{-ax}}$	[0,1]
Sigmóide Logística Simétrica	$f(x) = \frac{1}{1+e^{-x}} - 0.5$	[-0,5,+0,5]
Sigmóide Logística Simétrica Dupla	$f(x) = \frac{2}{1+e^{-x}} - 1$	[-1,+1]
Sigmóide Logística Simétrica com Quadrado	$f(x) = \frac{1}{1+e^{-x^2}} - 0.5$	[-0,5,+0,5]
Sigmóide Logística Simétrica Dupla com Quadrado	$f(x) = \frac{2}{1+e^{-x^2}} - 1$	[-1,+1]
Tangente Hiperbólica	$f(x) = Tanh(x)$	[-1,+1]

Tabela 2 - Funções de Ativação

O aprendizado da rede (item 1.5), em geral, pode ser mais rápido quando a funções de ativação sigmóide incorporada no modelo do neurônio for anti-simétrica do que quando ela for não simétrica. Uma função é anti-simétrica, também chamada função ímpar quando $f(-x) = -f(x)$ (HAYKIN, 2000).

A função Sigmóide Logística devido a sua suavidade na ativação e ao seu domínio [0,1], tende a evitar alguns problemas de convergência da rede, que

podem ocorrer devido à inversão dos sinais, positivo e negativo, de saída dos neurônios.

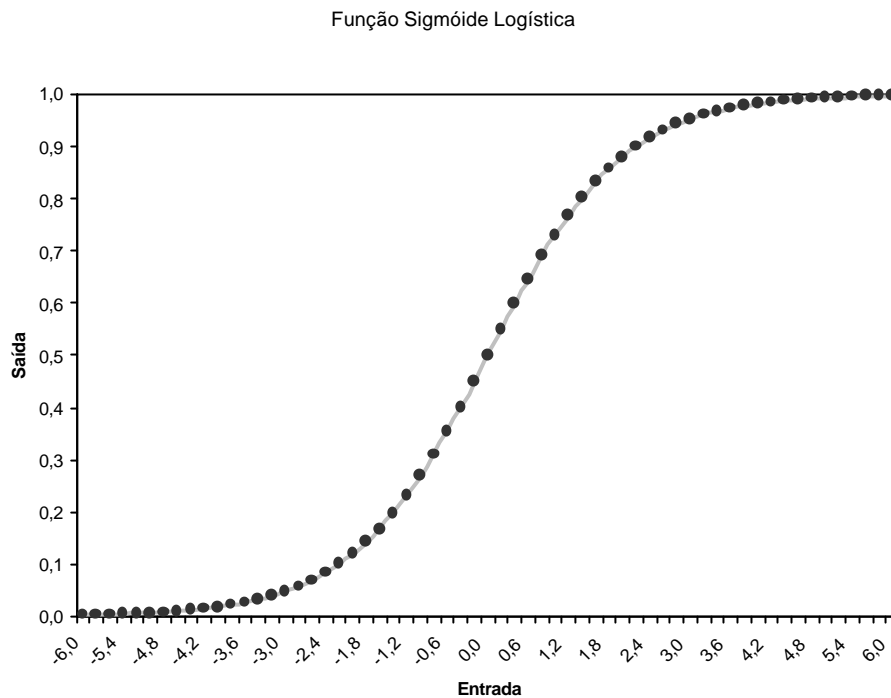


Figura 3 - Função de Ativação Sigmóide Logística

O parâmetro a utilizado na função Sigmóide Logística Parametrizada mostrada na Tabela 2 é o parâmetro de inclinação da função, quando maior o seu valor mais a função aproxima-se da função limiar, $f(x) = 0$ ou $f(x) = 1$, (HAYKIN, 2000).

1.4. REDES NEURAIS

Uma Rede Neural é um processador paralelamente distribuído constituído de unidades de processamento simples, os neurônios, que têm a propensão natural de armazenar conhecimento experimental e torná-lo disponível para o uso (HAYKIN, 2000). Assemelha-se ao cérebro humano por ser capaz de adquirir conhecimento a partir de seu ambiente através de um processo de aprendizagem e por armazená-lo modificando as intensidades das conexões entre os neurônios, conhecidas como pesos sinápticos.

A maneira como os neurônios são arranjados na rede neural define a arquitetura da rede, a qual é estreitamente relacionada ao tipo de conhecimento por ela armazenado.

A arquitetura mais comum dispõe os neurônios em camadas, de modo que os neurônios de uma dada camada possam conectar-se unicamente aos da camada imediatamente anterior e emitem seu sinal exclusivamente aos neurônios da camada posterior, como mostrado na Figura 4.




Figura 4 - Arquitetura Genérica de uma Rede Neural

Os neurônios da camada entrada (x_i) recebem os sinais provenientes do meio externo repassando-os à camada intermediária imediatamente posterior. Os neurônios das camadas intermediárias, ou escondidas, processam os sinais recebidos da camada anterior ponderados pelos pesos sinápticos, e, segundo sua função de ativação, emitem o sinal resultado à camada posterior, uma à outra até a camada de saída. Os neurônios da camada de saída (y_i) emitem o sinal resultado do padrão apresentado como entrada.

1.5. APRENDIZAGEM

Aprendizagem é o processo pelo qual os parâmetros livres de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida (HAYKIN, 2000). Dá-se pela modificação sistemática dos pesos sinápticos das conexões entre os neurônios das diversas camadas, de modo a armazenar o conhecimento apresentado à rede.

Um dos algoritmos de aprendizagem mais utilizados é conhecido como Propagação Retroativa do Erro (*backpropagation error*), sua descrição foi desenvolvida por RUMELHART et al. (1986).

O Back-Propagation é um algoritmo supervisionado que utiliza pares de entradas e saídas desejadas, para ajustar os pesos da rede por um mecanismo de correção erros. O aprendizado ocorre em duas etapas: na primeira os sinais de entrada são apresentados à rede, propagados pelas diversas camadas até a camada de saída, onde é comparado com a saída desejada. O erro gerado pela saída, é então retropropagado e os pesos das conexões reajustados. A Equação 2 mostra o cálculo do erro para a apresentação de todos os padrões p de entrada.

$$E = \frac{1}{2} \sum_p \sum_{i=1}^k (Xo_i^p - Xe_i^p)^2$$

Equação 2 - Erro da Rede Neural

em que:

E	erro total da rede	adm
Xo_i^p	valores observados na saída i	unid.
Xe_i^p	valores estimados na saída i	unid.
p	número de padrões	adm
k	número de unidades de saída	adm

O ajuste feito em um peso sináptico de um neurônio é proporcional ao produto do sinal de erro pelo sinal de entrada da sinapse em questão. Dessa forma, HAYKIN (2000), definem a correção dos pesos como:

$$w_{kj}(t+1) = w_{kj}(t) + \mathbf{hd}_j(t)x_k(t)$$

Equação 3 – Correção do Peso Sináptico

em que:

$w_{kj}(t+1)$	peso na conexão kj no tempo t+1	adm
$w_{kj}(t)$	peso na conexão kj no tempo t	unid.
η	taxa de aprendizagem da rede	unid.
$d_j(t)$	erro do neurônio j no tempo t	adm
$x_k(t)$	valor da entrada k no tempo t	adm

A taxa de aprendizagem η (pronuncia-se “eta”) da rede neural, como fator multiplicativo na correção dos pesos das conexões entre os neurônios, indica a rapidez com os pesos sinápticos são ajustados, ou em outras palavras, a velocidade de aprendizagem da rede.

À medida que a taxa de aprendizagem aumenta, o tempo necessário para a rede neural adquirir certo volume de conhecimento tende a diminuir. No entanto, um aumento excessivo na taxa de aprendizagem, pode acarretar instabilidade, pois os pesos seriam corrigidos abruptamente prejudicando a convergência da rede, isto é, a minimização do erro.

O processo de aprendizagem pode ser dividido ainda em duas etapas, conhecidas como fase de treinamento e fase de teste. Os padrões utilizados no aprendizado das redes neurais devem ser divididos em dois conjuntos de intersecção vazia, um para cada uma das fases.

O conjunto de treinamento, que engloba geralmente 75% dos padrões, é utilizado para a correção dos pesos das conexões, visando alcançar os valores desejados para a saída.

O conjunto de teste, contendo os 25% restantes, é utilizado apenas para calcular o erro total da rede, o qual objetiva-se minimizar. Por não alterar os pesos, a fase de teste não permite que a rede armazene o conhecimento sobre os padrões de teste, o qual é utilizado tão somente para verificar a quantidade e a qualidade do conhecimento armazenado pela rede, durante o treinamento.

Dessa forma, amplia-se a expectativa da rede neural gerar bons resultados para padrões semelhantes, mas não idênticos aos do conjunto completo, pois uma parte dele foi utilizada para ensinar e outra para avaliar. É

comum dividir os padrões de entrada em 3 conjuntos distintos: treinamento (60%), teste (20%) e validação (20%). Medindo o erro dos padrões de validação, que também não alteram os pesos da rede, é possível avaliar melhor o aprendizado da rede.

Um ciclo de aprendizagem constituído das fases de treinamento e teste é conhecido como *Época*. O número de épocas necessário a um bom ajustamento, varia principalmente com a complexidade do problema, com os pesos iniciais dados às conexões e com a taxa de aprendizagem.

Segundo BRAGA et al. (2000), uma das formas mais frequentes de acelerar o processo de treinamento e evitar mínimos locais é adicionar o termo α (*momentum*) à correção dos pesos.

$$\mathbf{u} = \alpha(w_{kj}(t) - w_{kj}(t-1))$$

Equação 4 – Termo Momentum

A equação de ajuste de pesos passa a ser:

$$w_{kj}(t+1) = w_{kj}(t) + \mathbf{hd}_j(t)x_k(t) + \alpha(w_{kj}(t) - w_{kj}(t-1))$$

Equação 5 – Correção do Peso Sináptico com Momentum

Overfitting (sobre-adequação) é um dos problemas que freqüentemente dificultam a utilização de redes neurais. Ocorre quando, depois de um dado número de épocas, apesar de diminuir o erro para os padrões de testes, o erro da validação começa a aumentar. Ou seja, a rede ao invés de aprender os padrões de treinamento, começa a memorizá-los por demais, perdendo a capacidade de inferência, por decorar suas peculiaridades e ruídos.

Segundo BRAGA et al. (2000), as alternativas mais comuns de evitar a sobre-adequação são: utilizar técnicas de poda (pruning) dos neurônios da rede ou encerrar o treinamento mais cedo, quando o erro de validação começar a subir.

1.6. REDE NEURAL MULTIVARIADA

Redes Neurais Multivariadas são assim chamadas por trabalharem com Séries Temporais Multivariadas que são conjuntos de valores de determinadas variáveis ordenadas no tempo, que mantêm entre si uma correlação ou indefinível ou não suficientemente clara, onde o comportamento de uma das variáveis pode ou não depender das demais.

CHAKRABORTY et al. (1992) obtiveram notável sucesso no treinamento de redes neurais para aprender a curva de preço de quatro produtos em três cidades simultaneamente, Buffalo, Minneapolis e Kansas City, por meio do qual foi possível realizar acuradas previsões de preços para cada delas separadamente.

SOARES e SOARES (1999) aplicaram redes neurais à previsão de temperatura, utilizando os dados da estação meteorológica do Maracanã, fornecido pela UERJ - Universidade Estadual do Rio de Janeiro, e concluíram que modelos que utilizam mais variáveis de entrada (modelos multivariados), apesar de serem mais complexos, podem fornecer melhores resultados do que aqueles que utilizam uma única variável para gerar estimativas futuras.

PESSOA e FREIRE (1998) utilizaram os dados da estação climática da ESALQ/USP - Escola Superior de Agricultura Luiz Queiroz, presente no campus da Universidade de São Paulo, Piracicaba (SP), que registra dados diários desde 1917, em redes neurais para realizar previsões conjuntas de precipitação e temperatura, e perceberam que a sazonalidade, isto é, agrupamento temporal dos dados (semanais, mensais,...) melhorou a eficiência da previsão.

1.7. APLICAÇÕES

A utilização de redes neurais está vinculada à possibilidade de representar as informações do problema em questão, em um conjunto numérico de dados que possa servir de entrada aos neurônios da rede.

O conhecimento do volume de água no solo é requerido por muitas aplicações na agricultura, recursos naturais e engenharia. ALTENDORF et al. (1999) utilizaram redes neurais na predição da quantidade de água no solo e comparam à técnicas de regressão. Um conjunto de redes neurais foi desenvolvido para prever a umidade de determinados tipos de solos, numa dada profundidade, associadas à temperatura do solo.

SARMENTO (1996) utilizou redes neurais na modelagem de séries hidrológicas. Para demonstrar a possibilidade de uso desta técnica foram apresentadas duas aplicações, a primeira referente à simulação da relação chuva-vazão a nível mensal em uma bacia da região semi-árida do Nordeste, e a segunda na previsão de vazões médias mensais diárias com intervalos de 1 ou 2 dias, fazendo uso das séries fluviométricas da bacia do Leine, na Alemanha.

A necessidade crescente de troca de informações entre o homem e a máquina, e a pressão do mercado no sentido de simplificar e humanizar este relacionamento motivam trabalhos na área de reconhecimento de voz. DINIZ (1997) utilizou redes neurais para o reconhecimento de dez palavras comuns em vídeo cassetes disponíveis no mercado: liga, pare, grave, avance, siga, volte, ejete, desliga e apague, dentre as quais obteve excelente performance para o reconhecimento de nove delas.

EBERHART e DOBBINS (1990) utilizaram redes neurais na composição de músicas. As canções utilizadas na aprendizagem foram representadas por um conjunto de dois de valores, um referente à frequência da nota e o outro à duração, representando, dessa forma, somente a melodia ou solo, pois o acompanhamento requer redes mais sofisticadas. As canções utilizadas na aprendizagem foram codificadas segundo esse critério e as saída foram decodificadas de modo que pudessem ser transcritas em partituras.

1.8. ALGORITMOS HÍBRIDOS

As técnicas existentes no campo da inteligência artificial, dentre elas redes neurais, algoritmos genéticos, lógica nebulosa, sistemas especialistas, etc, apresentam habilidades específicas para resolver determinados tipos de problema, do mesmo modo que possuem restrições inerentes à própria modelagem. Assim, a combinação criativa dessas técnicas conhecidas como algoritmos híbridos, poderia resultar em melhores resultados, por remediar as limitações de um método pelas aptidões de outros.

MENDES FILHO e CARVALHO (1997) experimentaram Neuro-Genética, isto é, a integração entre redes neurais e algoritmos genéticos, objetivando encontrar as redes capazes de realizar as melhores avaliações de crédito, comuns em empresas de cartões de crédito. NEVES e CORTEZ (1997) utilizaram técnica semelhante em previsões de manchas solares.

1.9. ERROS DE PREDIÇÃO

Para quantificar os erros de predição gerados pelas redes neurais é usual utilizar o *Erro Padrão de Estimativa* e o *Erro Relativo Médio*. O *Coefficiente de Determinação* também pode ser utilizado como medida da capacidade de previsão das redes.

O erro padrão de estimativa, ou desvio padrão do erro se expressa na mesma unidade da variável (COSTA NETO, 1999), indicando a variação média esperada para os valores estimados. Segundo HILL et al. (2000) um dos pressupostos do modelo de regressão linear simples é que o valor médio do erro aleatório seja igual zero ($E(e) = 0$).

$$d(e) = \sqrt{\frac{(\sum X_o - X_e)^2}{n}}$$

Equação 6 – Erro Padrão de Estimativa

em que:

$d(e)$	erro padrão de estimativa (EPE)	unid
X_o	valores observados	unid.
X_e	valores estimados	unid.
n	número de elementos da população	adm

O erro relativo médio mede o erro como a diferença proporcional entre a saída desejada e a saída obtida, sendo assim uma medida de erro mais realista para problemas de previsão do que o erro padrão de estimativa (ANDRADE et al., 1997). Enquanto o erro padrão de estimativa apresenta um valor médio do erro para toda a série de previsões realizadas, o erro relativo médio, desprezando a unidade, sugere uma proporção que promove diferentes erros para valores altos e baixos desta série.

$$\bar{R}(e) = \frac{1}{n} \sum \left| \frac{X_o - X_e}{X_o} \right|$$

Equação 7 - Erro Relativo Médio

em que:

$\bar{R}(e)$	erro relativo médio (ERM)	unid
X_o	valores observados	unid.
X_e	valores estimados	unid.
n	número de elementos da população	adm

O coeficiente de determinação, $0 \leq r^2 \leq 1$, indica a proporção da variação dos valores observados, que é explicada (determinada) pela regressão (valores estimados), sendo tanto mais útil quanto mais próximo de 1 estiver o valor de r^2 (HOFFMAN e VIEIRA, 1983).

$$r^2 = \frac{\left(\sum X_o X_e - \frac{\sum X_o \sum X_e}{n} \right)^2}{\left(\sum X_o^2 - \frac{(\sum X_o)^2}{n} \right) \left(\sum X_e^2 - \frac{(\sum X_e)^2}{n} \right)}$$

Equação 8 - Coeficiente de Determinação

em que:

r^2	coeficiente de determinação	adm
X_o	valores observados	unid.
X_e	valores estimados	unid.

O coeficiente de determinação entendido como medida da capacidade de previsão do modelo sobre o mesmo período amostral, é uma medida do ajuste da regressão aos dados. Valores altos de r^2 indicam que há estreita associação entre os valores observados e os previstos pelo modelo (HILL et al, 2000).

2. MATERIAIS E MÉTODOS

2.1. DADOS CLIMÁTICOS

Os dados climáticos utilizados neste trabalho são originários da estação número 83642 do INMET – Instituto Nacional de Meteorologia, localizada no município de Viçosa, estado de Minas Gerais, e foram obtidos junto ao Departamento de Engenharia Agrícola da Universidade Federal de Viçosa.

A série história registrada nesta estação compreende o período de 1961 a 2001, constituindo 41 anos de dados climáticos diários, referentes a diversas variáveis meteorológicas das quais foram selecionadas:

Tm	temperatura média diária	°C
Tn	temperatura mínima diária	°C
Tx	temperatura máxima diária	°C
Ur	umidade relativa diária	%
Vv	velocidade do vento diária medida a 10 metros de altura	m s ⁻¹
Inso	número de horas de brilho solar diária (insolação)	horas

A evapotranspiração de referência foi calculada para cada um dos dias da série histórica utilizando a Equação 1, gerando valores compreendidos entre 0,90 e 7,09mm para toda a série histórica.

MELLO (1998) conclui que o maior coeficiente de sensibilidade relativa, dentre os componentes analisados para o cálculo da evapotranspiração de referência pelo método Penman-Monteith, foi a radiação solar com 0,87 e que comparando a radiação solar medida com a estimada por meio da equação de Ångström-Prèscott, com os coeficientes propostos por Doorenbos e Pruitt, usada nos cálculos e mostrada na Equação 9, o valor medido superou o estimado em 1,9%.

É fácil perceber pela equação a seguir que quando a insolação é igual zero, comum em dias chuvosos ou nublados, a radiação é 25% da radiação extraterrestre, o que justifica o valor mínimo 0,9mm.

$$R_s = \left(a + b \frac{n}{N} \right) R_a$$

Equação 9 – Equação Angström-Prèscott

em que:

R_s	radiação solar efetiva	$\text{MJ m}^{-2}\text{d}^{-1}$
R_a	radiação extraterrestre	$\text{MJ m}^{-2}\text{d}^{-1}$
n	número de horas brilho solar	horas
N	duração do dia	horas
a	parâmetro, $a = 0,25$	adm
b	parâmetro, $b = 0,50$	adm

2.2. PROGRAMA COMPUTACIONAL

Para facilitar a manipulação das redes neurais durante a realização das simulações foi desenvolvido o programa Smart Climate (Figura 5).

O programa foi desenvolvido sobre a plataforma Microsoft Windows, utilizando o compilador Delphi 7.0, sendo as informações de entrada e saída gravadas em arquivo texto, os quais podem ser editados por outras ferramentas como o Microsoft Excel.

Para verificar o corretismo das equações utilizadas no programa, foi gerada, a partir da função $\text{sen}(x)$, uma série de 120 dados distribuídos uniformemente em 10 períodos. Cada valor gerado sofreu uma variação aleatória de 0 a 5%.

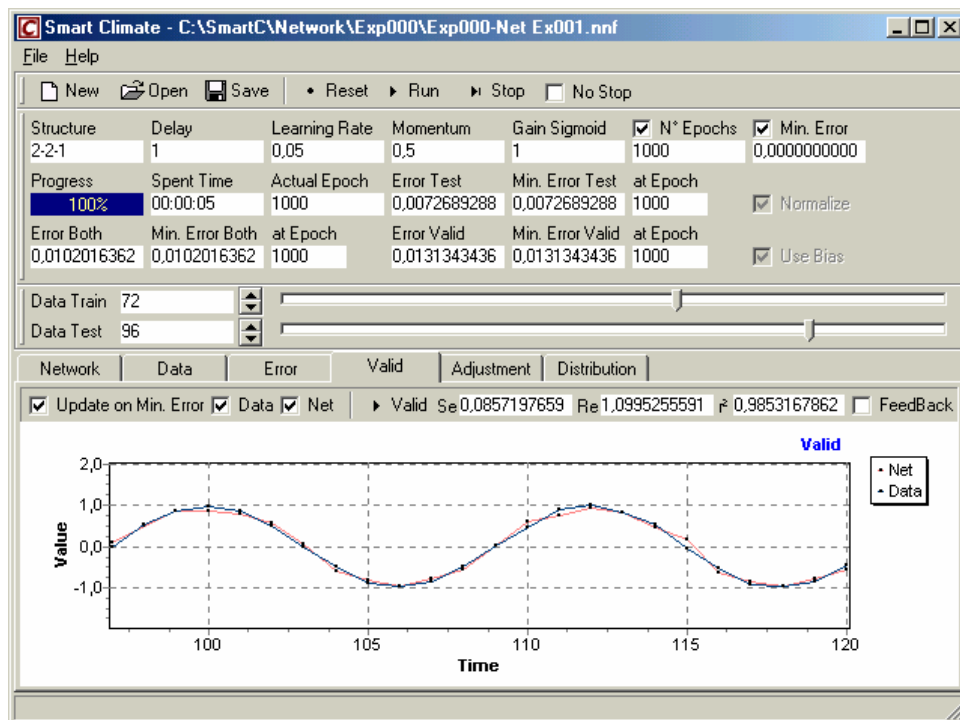


Figura 5 – Software Smart Climate

A estrutura utilizada foi 2-2-1, ou seja, 2 neurônios na camada de entrada, 2 na camada intermediária e 1 na camada de saída. A taxa de aprendizagem foi de 0,05, o momentum de 0,5 durante 1000 épocas. O desvio padrão do erro foi 0.0821 e o ajustamento pode ser visualizado na Figura 5.

Para simplificar a escrita utiliza-se, deste ponto em diante, a notação Rede [Estrutura; Taxa de Aprendizagem; Momentum; Época]. Assim, a rede citada acima será descrita como [2-2-1; 0,05; 0,5; 1000].

2.3. REDE NEURAL ORIENTADA A OBJETOS

A maioria das implementações de redes neurais em linguagem de programação utiliza arranjos ou matrizes para armazenar os valores (pesos, erros, etc.) dos objetos, seguindo de perto sua definição matemática.

No entanto, a metodologia de programação conhecida como Orientação a Objetos, baseada na construção de estruturas independentes que se comunicam através de funções ou mensagens, permite a construção de modelos mais próximos da realidade, auxiliando no seu entendimento e facilitando a inclusão de novas características.

A implementação orientada a objetos é sem dúvida menos eficiente do que as implementações tradicionais, no âmbito de tempo computacional, mas oferece um maior conforto no desenvolvimento e na manutenção do software. CONDE e ABELÉN (1997) desenvolveram um modelo orientado a objetos de uma rede neural artificial, e concluíram que a utilização dessa metodologia torna mais agradável a tarefa de modelar, projetar e implementar uma rede neural.

A seguir, é mostrado um esquema básico da estrutura da rede neural utilizada no programa. Note que as funcionalidades dos objetos foram omitidas por terem sido descritas em outros itens.

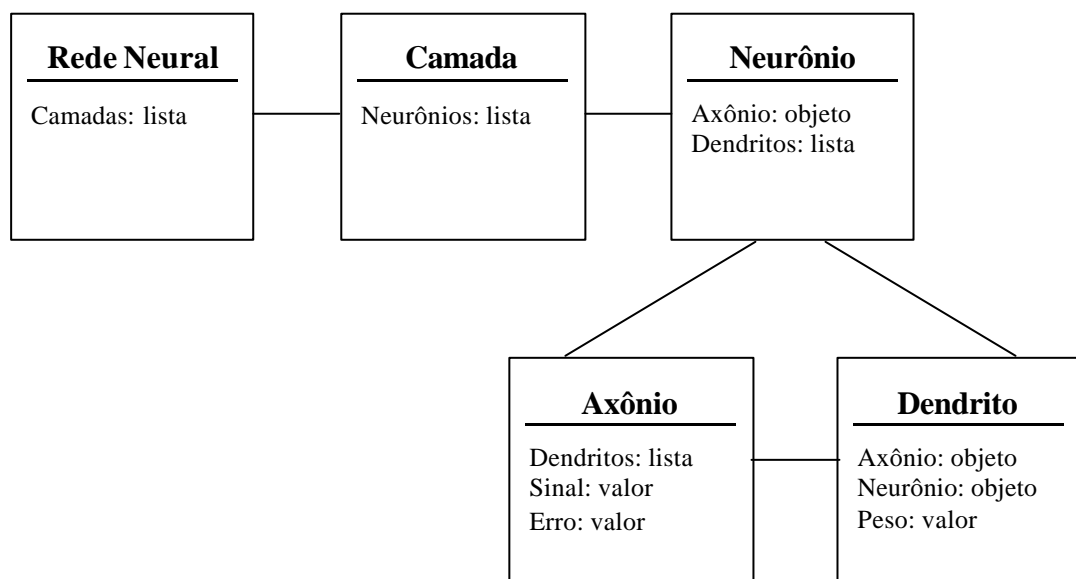


Figura 6 – Rede Neural Orientada a Objetos

2.4. SOBRE-ADEQUAÇÃO

É difícil precisar a época na qual a rede começa a perder sua capacidade de inferência por aprender em excesso os padrões de treinamento, mesmo utilizando os padrões de validação como referência.

A solução encontrada foi armazenar 3 redes simultaneamente durante o processo de aprendizagem: a primeira especialista nos padrões de teste, ou seja, apresenta o menor erro de teste; a segunda especialista nos padrões de validação, ou seja, apresenta o menor erro de validação e a terceira especialista em ambos os conjuntos, isto é, apresenta o menor erro médio entre os padrões de teste e validação.

Uma rede que apresente erros baixos para a massa de dados de teste e erros altos para a massa de validação, sendo que a época de obtenção do primeiro foi posterior a do segundo, provavelmente sofreu sobre-adequação. Uma alternativa para estes casos seria descartar ambas as redes e utilizar a rede obtida com os erros médios.

2.5. FUNÇÃO DE ATIVAÇÃO

A função Sigmóide Logística (Figura 3) foi utilizada devido sua suavidade na ativação dos sinais dos neurônios. Como o domínio desta função está compreendido entre 0 e 1, os dados climáticos tiveram que ser normalizados neste intervalo. A combinação desses dois elementos tende a evitar problemas na convergência da rede, que podem ocorrer devido à inversão, positivo e negativo, dos sinais de saída dos neurônios.

$$X_{norm} = \left(\frac{X_o - X_n}{X_x - X_n} \right) * (LimSup - LimInf) + LimInf$$

Equação 10 – Normalização dos Dados

em que:

Xnorm	Valor Normalizado
Xo	Valor Original
Xn	Valor Mínimo de Xo
Xm	Valor Máximo de Xo
LimInf	Limite Inferior da Normalização (= 0,1)
LimSup	Limite Superior da Normalização (= 0,9)

2.6. INICIALIZAÇÃO DOS PESOS

Os pesos sinápticos nas redes neurais foram iniciados com valores aleatórios no intervalo $[-0,5;+0,5]$, embora HAYKIN (2000) afirme que o uso tanto de valores grandes como de valores pequenos para a inicialização dos pesos deva ser evitado. O intervalo que oferece a melhor relação rapidez versus ajuste, deve ser obtido por meio de simulações, pois está relacionado intrinsecamente às características do conhecimento a ser representado.

CASTRO e VON ZUBEN (1998) apresentam uma alternativa simples e robusta para a inicialização dos pesos em redes neurais multicamadas, sugerindo a utilização de um algoritmo híbrido intermediário aos métodos do caminho mais fácil e do caminho mais curto, procurando encontrar uma condição inicial que, ao mesmo tempo, possa acelerar o processo de treinamento e seja o mais próximo possível da solução ótima.

2.7. NÚMERO IDEAL DE ANOS

A primeira simulação tem por objetivo definir o menor conjunto de anos com os quais seja possível explicar o comportamento da evapotranspiração de referência ao longo da série histórica.

Com este fim, foram treinadas 9 redes neurais em duas simulações: a primeira utilizando redes [5-5-1; 0,01; 0,01; 10.000] e a segunda utilizando redes [10-20-20-1; 0,5; 0,5; 20.000].

Dentre os 41 anos disponíveis na série original, foram utilizados 40, 30, 20 e 10. É bastante comum dividir os padrões disponíveis em 60%, 20% e 20% (d: 60%; 20%; 20%), para os padrões de treinamento, teste e validação, respectivamente. Dessa forma, para 40 anos de dados a divisão seria d: [24; 8; 8]. Algumas exceções foram também embutidas para ampliar as possibilidades das simulações.

Tabela 3 - Número Ideal de Anos

rede	período	anos	dados
1	1962 a 2001	40	d: 36-2-2
2	1972 a 2001	30	d: 26-2-2
3	1982 a 2001	20	d: 16-2-2
4	1992 a 2001	10	d: 6-2-2
5	1962 a 2001	40	d: 32-4-4
6	1972 a 2001	30	d: 22-4-4
7	1982 a 2001	20	d: 12-4-4
8	1962 a 2001	40	d: 24-8-8
9	1972 a 2001	30	d: 14-8-8

2.8. PARÂMETROS DAS REDES NEURAIIS

Os parâmetros analisados para as redes neurais foram: estrutura, taxa de aprendizagem, fator momentum e ainda número de épocas executadas.

As estruturas podem variar em relação ao número de neurônios da camada de entrada, ao número de camadas intermediárias e sua respectiva quantidade de neurônios, e enfim, ao número neurônios na camada de saída. Os valores utilizados para a taxa de aprendizagem foram 0,01; 0,1; 1 e 10. Também para o fator momentum foram utilizados os valores 0,01; 0,1; 1 e 10. O número de épocas variou entre 1.000, 5.000, 10.000 e 20.000, dependendo da simulação.

2.9. TAXA DE APRENDIZAGEM, FATOR MOMENTUM E NÚMERO DE ÉPOCAS

A segunda simulação procurou encontrar valores razoáveis para a taxa de aprendizagem e para o fator momentum, que permitam a variação da estrutura das redes sem prejuízo à qualidade dos resultados obtidos.

O número de épocas definido foi 20.000, sendo que nas épocas número 1.000, 5.000, 10.000 e 20.000, foram registrados os melhores resultados obtidos, o que permite saber qual o número de épocas apresenta melhor combinação entre a qualidade do resultado e o tempo computacional.

Dessa forma, utilizando o melhor conjunto de anos obtido na simulação 01, arbitrariamente definiu-se a rede [10-10-1] para ser treinada de acordo com casos a seguir:

Tabela 4 – Taxa de Aprendizagem, Fator Momentum e Número de Épocas

rede	taxa aprendizagem	fator momentum	épocas
1	0,01	0,01	1.000, 5.000, 10.000 e 20.000
2	0,01	0,10	1.000, 5.000, 10.000 e 20.000
3	0,01	1,00	1.000, 5.000, 10.000 e 20.000
4	0,01	10,00	1.000, 5.000, 10.000 e 20.000
5	0,10	0,01	1.000, 5.000, 10.000 e 20.000
6	0,10	0,10	1.000, 5.000, 10.000 e 20.000
7	0,10	1,00	1.000, 5.000, 10.000 e 20.000
8	0,10	10,00	1.000, 5.000, 10.000 e 20.000
9	1,00	0,01	1.000, 5.000, 10.000 e 20.000
10	1,00	0,10	1.000, 5.000, 10.000 e 20.000
11	1,00	1,00	1.000, 5.000, 10.000 e 20.000
12	1,00	10,00	1.000, 5.000, 10.000 e 20.000
13	10,00	0,01	1.000, 5.000, 10.000 e 20.000
14	10,00	0,10	1.000, 5.000, 10.000 e 20.000
15	10,00	1,00	1.000, 5.000, 10.000 e 20.000
16	10,00	10,00	1.000, 5.000, 10.000 e 20.000

2.10. NÚMERO DE NEURÔNIOS

A terceira simulação utiliza o melhor conjunto de anos de acordo com a simulação 01 e os melhores valores encontrados para a taxa de aprendizagem e para o fator momentum encontrados na simulação 02, variando o número de neurônios das camadas de entrada, intermediária e de saída. As redes nesta simulação são da forma [e-x-s], onde x é o número de neurônios na camada intermediária.

Esta simulação foi dividido em dois módulos. O primeiro módulo combina 10, 20 e 30 neurônios na camada de entrada, com 10, 20 e 30 na camada intermediária e com 1, 2 e 5 neurônios na camada de saída. O segundo módulo combina 60, 90 e 120 neurônios na camada de entrada, com 10, 20 e 30 neurônios na camada intermediária e com 10 neurônios na camada de saída.

Tabela 5 – Número de Neurônios – Módulo 01

rede	estrutura	“x”
1	[10-x-1]	10, 20 e 30
2	[10-x-2]	10, 20 e 30
3	[10-x-5]	10, 20 e 30
4	[20-x-1]	10, 20 e 30
5	[20-x-2]	10, 20 e 30
6	[20-x-5]	10, 20 e 30
7	[30-x-1]	10, 20 e 30
8	[30-x-2]	10, 20 e 30
9	[30-x-5]	10, 20 e 30

Tabela 6 – Número de Neurônios – Módulo 02

rede	estrutura	“x”
1	[060-x-10]	10, 20 e 30
2	[090-x-10]	10, 20 e 30
3	[120-x-10]	10, 20 e 30

2.11. REDES DE MÚLTIPLAS CAMADAS

A quarta simulação tem por objetivo verificar a melhoria dos resultados pela inclusão de uma segunda camada intermediária. Assim, as redes testadas são da forma [e-x-y-s], onde x e y são os números de neurônios da primeira e da segunda camada intermediária respectivamente. O número de neurônios utilizado para cada camada intermediária foi de 10, 20 e 30. A rede [30-60-60-1] foi testada como caso extremo.

Tabela 7 – Redes de Múltiplas Camadas

rede	estrutura
1	[10-10-10-1]
2	[10-10-20-1]
3	[10-10-30-1]
4	[10-20-10-1]
5	[10-20-20-1]
6	[10-20-30-1]
7	[10-30-10-1]
8	[10-30-20-1]
9	[10-30-30-1]
10	[30-60-60-1]

2.12. REDES MULTIVARIADAS

Todos as simulações anteriores utilizaram a série histórica de evapotranspiração para realizar previsões de evapotranspiração. A possibilidade de, ao invés da evapotranspiração calculada, utilizar a série histórica das variáveis necessárias ao cálculo evapotranspiração diária, vislumbra uma melhoria dos resultados das previsões, uma vez que o “conhecimento” armazenado na série das variáveis é certamente maior. Resta saber se as componentes aleatórias presentes em cada uma dessas séries são, em conjunto, maior que a componente aleatória existente na série de evapotranspiração.

A quinta e última simulação é dividida em 3 módulos. O primeiro módulo é uma comparação entre redes uni e multivariadas. Para isso, a rede [10-10-1] foi escolhida.

Tabela 8 – Redes Multivariadas – Módulo 01

rede ³	estrutura (m = multivariada)
1	[70m-10-1]
2	[10-10-1]
3	[70m-20-1]
4	[10-20-1]
5	[70m-30-1]
6	[10-30-1]

O segundo módulo procura comparar redes que realizam previsões para 5 dias. A rede multivariada [140m-10-10-5] de duas camadas intermediárias, utiliza 20 dias para realizar 5 dias de previsão, sendo comparada a redes univariadas cujo número de neurônios na camada de entrada é de 10, 20 e 30, na camada intermediária também de 10, 20 e 30, sempre prevendo 5 dias.

Tabela 9 – Redes Multivariadas – Módulo 02

rede	estrutura (m = multivariada)
1	[140m-10-10-5]
2	[10-10-05]
3	[10-20-05]
4	[10-30-05]
5	[20-10-05]
6	[20-20-05]
7	[20-30-05]
8	[30-10-05]
9	[30-20-05]
10	[30-30-05]

³ As redes neurais de 1, 3 e 5 foram obtidas na simulação 03.

O terceiro módulo procura comparar redes que realizam previsões para 10 dias. A rede multivariada [140m-20-10], utiliza 20 dias como entrada e é comparada a redes univariadas cujo número de neurônios na camada de entrada é de 60, 90 e 120, sempre prevendo 10 dias.

Tabela 10 – Redes Multivariadas – Módulo 03

rede	estrutura (m = multivariada)
1	[140m-20-10]
2	[060-20-10]
3	[090-20-10]
4	[120-20-10]

2.13. ERROS DE PREDIÇÃO

Para quantificar os erros de predição gerados pelas redes neurais foram utilizados o erro padrão de estimativa e o erro relativo médio, comentados na seção 1.9.

3. RESULTADOS E DISCUSSÃO

3.1. EQUIPAMENTO

Todas as simulações a seguir foram realizadas em um computador Pentium III 850 MHz, 256 MBytes de memória RAM, 20 MBytes de HD e sistema operacional Windows 2000. O equipamento teve sua utilização restringida a esse fim, enquanto se processava a execução das redes.

3.2. SIMULAÇÃO 01

Os resultados dos diversos testes realizados com as redes [5-5-1] e [10-20-20-1], são apresentados a seguir:

Tabela 11 - Número Ideal de Anos – Rede [5-5-1]

Rede	Período	Anos	Dados	ERM	Época	Tempo
1	1962 a 2001	40	d: 36-2-2	0,2132926903	83	00:29:32
2	1972 a 2001	30	d: 26-2-2	0,2137035622	66	00:22:41
3	1982 a 2001	20	d: 16-2-2	0,2127940141	10000	00:13:56
4	1992 a 2001	10	d: 6-2-2	0,2126057669	284	00:06:11

5	1962 a 2001	40	d: 32-4-4	0,2195640244	1517	00:30:56
6	1972 a 2001	30	d: 22-4-4	0,2195904784	1211	00:21:02
7	1982 a 2001	20	d: 12-4-4	0,2191475727	1121	00:13:05
8	1962 a 2001	40	d: 24-8-8	0,2149126606	10000	00:28:00
9	1972 a 2001	30	d: 14-8-8	0,2155306002	8721	00:16:13

Tabela 12 - Número Ideal de Anos – Rede [10-20-20-1]

Rede	Período	Anos	Dados	ERM	Época	Tempo
1	1962 a 2001	40	d: 36-2-2	0,2132926903	83	00:29:32
2	1972 a 2001	30	d: 26-2-2	0,2137035622	66	00:22:41
3	1982 a 2001	20	d: 16-2-2	0,2127940141	10000	00:13:56
4	1992 a 2001	10	d: 6-2-2	0,2126057669	284	00:06:11
5	1962 a 2001	40	d: 32-4-4	0,2195640244	1517	00:30:56
6	1972 a 2001	30	d: 22-4-4	0,2195904784	1211	00:21:02
7	1982 a 2001	20	d: 12-4-4	0,2191475727	1121	00:13:05
8	1962 a 2001	40	d: 24-8-8	0,2149126606	10000	00:28:00
9	1972 a 2001	30	d: 14-8-8	0,2155306002	8721	00:16:13

Nota-se que apesar da variação na complexidade da rede e nos número de anos utilizados no treinamento, teste e validação, os resultados obtidos para o erro relativo médio não apresentaram variação significativa. Assim sendo, optou-se por realizar o restante das simulações desse trabalho com d: [6-2-2], ou seja, 6 anos para treinamento (1992 a 1997), 2 para teste (1998 e 1999) e 2 para validação (2000 e 2001).

O tempo despendido para completar as 20.000 épocas das redes [10-20-20-1], demonstra uma necessidade muita elevada de tempo computacional, que deve ser considerada no desenvolvimento de trabalhos deste porte.

3.3. SIMULAÇÃO 02

Os resultados da simulação 02, para as redes [10-10-1; 0,01] são apresentados a seguir:

Tabela 13 - Rede [10-10-1; 0,01; (0,01;0,10;1,00;10,0)]

Épocas	Estrutura	Aprend.	Moment.	EPE	ERM	Na Época
1000	10-10-1	0,01	0,01	0,7922614300	0,2088636163	366
5000	10-10-1	0,01	0,01	0,7922614300	0,2088636163	366
10000	10-10-1	0,01	0,01	0,7922614300	0,2088636163	366
20000	10-10-1	0,01	0,01	0,7922614300	0,2088636163	366
1000	10-10-1	0,01	0,10	0,7931749637	0,2093753217	295
5000	10-10-1	0,01	0,10	0,7931749637	0,2093753217	295
10000	10-10-1	0,01	0,10	0,7931749637	0,2093753217	295
20000	10-10-1	0,01	0,10	0,7931749637	0,2093753217	295
1000	10-10-1	0,01	1,00	0,7931749637	0,2093753217	180
5000	10-10-1	0,01	1,00	0,7945169047	0,2118518389	180
10000	10-10-1	0,01	1,00	0,7945169047	0,2118518389	180
20000	10-10-1	0,01	1,00	0,7945169047	0,2118518389	180
1000	10-10-1	0,01	10,0	0,7945169047	0,2118518389	1000
5000	10-10-1	0,01	10,0	0,8290174820	0,2387997667	2926
10000	10-10-1	0,01	10,0	0,8041794496	0,2230089303	2926
20000	10-10-1	0,01	10,0	0,8041794496	0,2230089303	2926

Nota-se que para cada fator momentum 0,01, 0,10 e 1,00; a época na qual foi encontrado o melhor resultado diminuiu respectivamente de 366 para 295 e 180. Demonstrado fica, neste caso, que o aumento do fator momentum promoveu um aumento de performance da rede, pois promoveu mesmos resultados em menos iterações (passos computacionais). No entanto, a utilização do fator momentum 10, causou certa instabilidade na rede, aumentando os erros encontrados e suas respectivas épocas de obtenção.

Além das informações expostas anteriormente, percebeu-se que o menor erro de validação para a rede [10-10-1; 0,01; 0,01] foi encontrado na época 9969, bem depois da época 366 na qual encontro-se o menor erro de teste. Isto indica que os padrões de validação, isto é, os anos de 2000 e 2001, são aparentemente mais semelhantes aos anos de treinamento, 1992 a 1997, que os anos escolhidos para teste, 1998 e 1999.

Os resultados da simulação 02, para as redes [10-10-1; 0,10] são apresentados a seguir:

Tabela 14 - Rede [10-10-1; 0,10; (0,01;0,10;1,00;10,0)]

Épocas	Estrutura	Aprend.	Moment.	EPE	ERM	Na Época
1000	10-10-1	0,10	0,01	0,8226363187	0,2348074632	1000
5000	10-10-1	0,10	0,01	0,8057301464	0,2215242309	3945
10000	10-10-1	0,10	0,01	0,8033132636	0,2196287232	6474
20000	10-10-1	0,10	0,01	0,8033132636	0,2196287232	6474
1000	10-10-1	0,10	0,10	0,8104244197	0,2260596536	1000
5000	10-10-1	0,10	0,10	0,8008275802	0,2169693570	3437
10000	10-10-1	0,10	0,10	0,8008275802	0,2169693570	3437
20000	10-10-1	0,10	0,10	0,8008275802	0,2169693570	3437
1000	10-10-1	0,10	1,00	0,8264242360	0,2389432625	1000
5000	10-10-1	0,10	1,00	0,8061194911	0,2223789458	3217
10000	10-10-1	0,10	1,00	0,8061194911	0,2223789458	3217
20000	10-10-1	0,10	1,00	0,8061194911	0,2223789458	3217
1000	10-10-1	0,10	10,0	1,2222421323	0,4270372214	1000
5000	10-10-1	0,10	10,0	1,1930385379	0,4141875643	1487
10000	10-10-1	0,10	10,0	1,1930385379	0,4141875643	1487
20000	10-10-1	0,10	10,0	1,1930385379	0,4141875643	1487

Podemos perceber que o aumento da taxa de aprendizagem de 0,01 para 0,10 causou um aumento do erro padrão de estimativa, de cerca de 0,79mm para 0,80mm. Apesar desse valor ser insignificante por se tratar da evapotranspiração, é interessante notar, que neste caso, o aumento da taxa de aprendizagem gerou um efeito inverso do de acelerar o aprendizado, aumentando não só a época da obtenção do melhor resultado, como também o valor do erro em si.

Lembrando que a evapotranspiração da cultura é calculada multiplicando-se a evapotranspiração de referência por um fator de correção (K_c) que varia para cada estágio de crescimento, o erro da evapotranspiração real da cultura pode ser reduzido ou ampliado, se o K_c da fase atual for menor ou maior que 1, respectivamente.

Os resultados da simulação 02, para as redes [10-10-1; 1,00] são apresentados a seguir:

Tabela 15 - Rede [10-10-1; 1,00; (0,01;0,10;1,00;10,0)]

Épocas	Estrutura	Aprend.	Moment.	EPE	ERM	Na Época
1000	10-10-1	1,00	0,01	1,2320706013	0,4321113452	1000
5000	10-10-1	1,00	0,01	1,2280717429	0,4308484467	1318
10000	10-10-1	1,00	0,01	1,2280717429	0,4308484467	1318
20000	10-10-1	1,00	0,01	1,2280717429	0,4308484467	1318
1000	10-10-1	1,00	0,10	1,2972497731	0,4578407873	725
5000	10-10-1	1,00	0,10	1,2972497731	0,4578407873	725
10000	10-10-1	1,00	0,10	1,2972497731	0,4578407873	725
20000	10-10-1	1,00	0,10	1,2425074128	0,4290545246	20000
1000	10-10-1	1,00	1,00	1,8042421824	0,6476685120	1000
5000	10-10-1	1,00	1,00	1,7718889731	0,6355474521	1447
10000	10-10-1	1,00	1,00	1,7718889731	0,6355474521	1447
20000	10-10-1	1,00	1,00	1,7718889731	0,6355474521	1447
1000	10-10-1	1,00	10,0	3,3628722964	1,1582891184	199
5000	10-10-1	1,00	10,0	3,3628722964	1,1582891184	199
10000	10-10-1	1,00	10,0	3,2140661709	1,1380783237	8852
20000	10-10-1	1,00	10,0	3,2139498268	1,1381221611	10439

Utilizando o valor 1,00 para a taxa de aprendizagem, percebeu-se o mesmo efeito comentado anteriormente, porém com características mais marcantes. A porcentagem do erro, que era de 20%, utilizando taxa de aprendizagem e momentum igual 0,01, superou os 40% para momentum 0,01 e 0,10; ultrapassou os 60% para momentum 1,00; e atingiu os 100% para momentum 10, demonstrando neste último caso uma completa instabilidade da rede.

Tal instabilidade é ainda mais gritante, analisando os resultados da simulação 02, para as redes [10-10-1; 10,0]:

Tabela 16 - Rede [10-10-1; 10,0; (0,01;0,10;1,00;10,0)]

Épocas	Estrutura	Aprend.	Moment.	EPE	ERM	na Época
1000	10-10-1	10,0	0,01	3,9337602818	1,4239021807	498
5000	10-10-1	10,0	0,01	3,8109031409	1,3827074155	1602
10000	10-10-1	10,0	0,01	3,8109031409	1,3827074155	1602
20000	10-10-1	10,0	0,01	3,8109031409	1,3827074155	1602
1000	10-10-1	10,0	0,10	3,8190174264	1,3882817164	498

5000	10-10-1	10,0	0,10	3,8165479080	1,3837989818	1018
10000	10-10-1	10,0	0,10	3,8165479080	1,3837989818	1018
20000	10-10-1	10,0	0,10	3,8165479080	1,3837989818	1018
1000	10-10-1	10,0	1,00	3,1519345942	1,1534140032	113
5000	10-10-1	10,0	1,00	3,2066510267	0,8806412400	1095
10000	10-10-1	10,0	1,00	3,2066510267	0,8806412400	1095
20000	10-10-1	10,0	1,00	3,2066510267	0,8806412400	1095
1000	10-10-1	10,0	10,0	3,2731116600	0,9098501418	1000
5000	10-10-1	10,0	10,0	3,2726145199	0,9096745920	4365
10000	10-10-1	10,0	10,0	3,2660247495	0,9073251721	7118
20000	10-10-1	10,0	10,0	3,2660247495	0,9073251721	7118

Com base nos resultados obtidos nesta simulação, optou-se por utilizar a taxa de aprendizagem 0,01 e o fator momentum também 0,01, para o restante das simulações.

Na prática, esta mesma simulação deveria ser realizada novamente para valores da taxa de aprendizagem e do fator momentum em torno de 0,01, com o intuito de buscar ainda melhores valores dos já encontrados. No entanto, devido à proximidade dos erros obtidos e do caráter científico deste trabalho, tais valores foram tomados como satisfatórios.

O gráfico mostrado na Figura 7 apresenta os dados reais (azul) comparados com os dados de previsão (vermelho) gerados pela rede [10-10-1; 0,01; 0,01; 20.000], para os anos de 2000 e 2001. É possível notar que a rede neural foi capaz de gerar valores de previsão que acompanham a tendência da evapotranspiração real em ambos os anos.




Figura 7 - Rede [10-10-1; 0,01; 0,01; 20.000] – Dados Reais e Previsões

A Figura 8 exibe uma ampliação da Figura 7 para 50 dias de previsão, na qual é possível apreciar em maiores detalhes os ajustes proporcionados pela rede.




Figura 8 - Rede [10-10-1; 0,01; 0,01; 20.000] – Detalhes dos Dados Reais e Previsões

O gráfico da Figura 9 exibe os dados reais (eixo X) e suas respectivas previsões (eixo Y), apresentando a dispersão das previsões em torno do valor esperado ($y = x$).




Figura 9 - Rede [10-10-1; 0,01; 0,01; 20.000] - Dados Reais x Previsão

3.4. SIMULAÇÃO 03

Os resultados da simulação 03, para previsões de 1, 2, 5 e 10 dias, são apresentados nos quadros seguintes, os quais serão discutidos em conjunto.

Um erro padrão de estimativa de 0,8mm para a previsão da evapotranspiração de referência pode ser considerado um valor alto quando o contexto é o manejo da irrigação. Ainda, a previsão de apenas 1 dia é pouco útil, no que concerne ao tempo hábil de tomada de decisão do manejo.

Pelos resultados apresentados, percebe-se que tais erros se aproximaram de 0,8mm, 0,83mm, 0,96mm e 1,00mm para previsões de 1, 2, 5, 10 dias, respectivamente. Sabendo que a ocorrência do erro padrão de estimativa na prática pode ser para cima ou para baixo do valor real, a informação da ETo para 10 dias com erro de 1mm por dia torna viável sua utilização para este período.

Tabela 17 – Simulação 03 – Previsão 1 Dia

Rede	Estrutura	EPE	ERM	Ambos	Teste	Validação
1	[10-10-1]	0,7923895749	0,2088444694	387	318	2514
2	[10-20-1]	0,7930997766	0,2101869461	6329	328	3178
3	[10-30-1]	0,7962752537	0,2126334001	4619	285	5538
4	[20-10-1]	0,7930590252	0,2100106247	2467	2676	2151
5	[20-20-1]	0,7927225308	0,2112404059	2063	2153	1923
6	[20-30-1]	0,7974761328	0,2143640720	1601	272	1536
7	[30-10-1]	0,7930436567	0,2107944700	352	355	346
8	[30-20-1]	0,7938803404	0,2136499289	647	402	652
9	[30-30-1]	0,7951357944	0,2145005215	316	300	339

Tabela 18 – Simulação 03 – Previsão 2 Dias

Rede	Estrutura	EPE	ERM	Ambos	Teste	Validação
1	[10-10-2]	0,8279158882	0,2194331736	1682	2432	1208
2	[10-20-2]	0,8278508178	0,2198288667	2126	2229	2043
3	[10-30-2]	0,8297179482	0,2212522769	4852	6315	2516
4	[20-10-2]	0,8342101828	0,2227133945	1093	6232	883
5	[20-20-2]	0,8332954992	0,2231464469	848	688	972
6	[20-30-2]	0,8307797009	0,2232252646	1657	1834	1495
7	[30-10-2]	0,8318812023	0,2251487095	4276	488	4308
8	[30-20-2]	0,8318680058	0,2250270335	516	559	477
9	[30-30-2]	0,8338848620	0,2268360412	435	348	654

Tabela 19 – Simulação 03 – Previsão 5 Dias

Rede	Estrutura	EPE	ERM	Ambos	Teste	Validação
1	[10-10-5]	0,9687024389	0,2592994411	3347	10000	252
2	[10-20-5]	0,9689940493	0,2595258139	717	10000	244
3	[10-30-5]	0,9697259472	0,2598024793	6116	10000	200
4	[20-10-5]	0,9548115236	0,2603774603	938	1038	691
5	[20-20-5]	0,9635908087	0,2625471865	2775	4358	317
6	[20-30-5]	0,9693200975	0,2628398801	1060	9827	472
7	[30-10-5]	0,9609548689	0,2615368844	1098	1148	542
8	[30-20-5]	0,9597091545	0,2610633526	669	845	290
9	[30-30-5]	0,9591376040	0,2604296815	750	1002	352

Tabela 20 – Simulação 03 – Previsão 10 Dias

Rede	Estrutura	EPE	ERM	r2	Ambos	Teste	Validação
1	[60-10-10]	0,9930731918	0,2786850350	0,3035910767	481	3716	435
2	[60-20-10]	1,0056134583	0,2788697109	0,2860867984	429	1521	249
3	[60-30-10]	1,0023171216	0,2804281327	0,2896020479	348	927	325
4	[90-10-10]	0,9764542880	0,2730930656	0,3240219370	269	277	262
5	[90-20-10]	0,9827587759	0,2759029388	0,3147533110	267	253	281
6	[90-30-10]	1,0063220388	0,2829577006	0,2852442018	225	244	209
7	[120-10-10]	0,9964353715	0,2750989193	0,2957912618	286	295	276
8	[120-20-10]	0,9730304671	0,2697850375	0,3276840676	257	267	248
9	[120-30-10]	1,0132853867	0,2788720892	0,2752697258	219	6604	198

Os gráficos a seguir apresentam a distribuição do erro para as redes [10-10-1], [10-10-2], [10-10-5] e [60-10-10], demonstrando a uniformidade de valores, positivos e negativos, obtidos em torno do valor esperado. É possível perceber, ainda, que à medida que o valor absoluto do erro aumenta, menor se torna o número de suas ocorrências. Ao longo do tempo, a combinação desses dois fatores gera uma tendência dos erros positivos compensarem os erros negativos, e vice-versa.




Figura 10 - Distribuição do Erro da Rede 10-10-1




Figura 11 - Distribuição do Erro da Rede 10-10-2




Figura 12 - Distribuição do Erro da Rede 10-10-5




Figura 13 - Distribuição do Erro da Rede 60-10-10

3.5. SIMULAÇÃO 04

Os resultados da simulação 04 são apresentados a seguir. Nota-se que ao contrário do que se supunha, nem o acréscimo de mais uma camada intermediária, nem a variação do número de neurônios de cada camada conseguiu promover um melhora no resultado. Nem mesmo a complexidade da rede [30-60-60-1] foi capaz de prover erros padrão de estimativa inferiores a 0,79mm.

As redes neurais com maior número de camadas intermediárias ou com maior número de neurônios nessas camadas têm a capacidade armazenar um maior “volume” de conhecimento, por possuírem maior número de conexões (sinapses) entre seus neurônios. O fato dessas redes não serem capazes de descobrir mais estreitas dependências entre os dados, deve-se provavelmente à existência de uma componente aleatória na série (ruído) responsável pelo erro de 20%.

Tabela 21 – Simulação 04

Rede	Estrutura	EPE	ERM	Ambos	Teste	Validação
1	[10-10-10-1]	0,7940486542	0,2104397946	2898	394	5648
2	[10-10-20-1]	0,7957077222	0,2127639609	4761	351	10000
3	[10-10-30-1]	0,7982238240	0,2157041719	9261	384	9124
4	[10-20-10-1]	0,7953466674	0,2130103233	3663	380	10000
5	[10-20-20-1]	0,7973867489	0,2148570885	10000	360	10000
6	[10-20-30-1]	0,7937549108	0,2123385465	10000	10000	10000
7	[10-30-10-1]	0,7970423065	0,2140724459	5745	345	10000
8	[10-30-20-1]	0,7924881985	0,2107365704	10000	10000	10000
9	[10-30-30-1]	0,7936762969	0,2121557793	10000	10000	10000
10	[30-60-60-1]	0,8086066900	0,2218418137	3816	3654	3955

Em virtude do oneroso tempo computacional, a rede [30-60-60-1] teve o seu treinamento interrompido na época número 4.000, processamento este que despendeu 23 horas, 26 minutos e 21 segundos.

3.6. SIMULAÇÃO 05

A derradeira tentativa de obter melhores resultados foi então o uso das variáveis climáticas envolvidas no cálculo de evapotranspiração de referência por Penman-Monteith. Os resultados da simulação 05, divididos em partes, são apresentados a seguir.

Tabela 22 – Simulação 05 – Módulo 01

Rede	Estrutura	EPE	ERM	Ambos	Teste	Validação
1	[70m-10-1]	0,8218872703	0,2216262714	364	5549	305
2	[70m-20-1]	0,8280817970	0,2241684618	193	9994	150
3	[70m-30-1]	0,8349394729	0,2275230600	194	4997	140
4	[10-10-1]	0,7923895749	0,2088444694	387	318	2514
5	[10-20-1]	0,7930997766	0,2101869461	6329	328	3178
6	[10-30-1]	0,7962752537	0,2126334001	4619	285	5538

Pelos dados obtidos acima, nota-se que o aumento do número de neurônios na camada intermediária não promoveu melhoria nos resultados, como já havia sido constatado na simulação 03. Em tempo, os erros encontrados utilizando redes multivariadas neste caso, foram levemente superiores, quando comparados a redes univariadas para previsões de 1 dia.

Tabela 23 – Simulação 05 – Módulo 02

Rede	Estrutura	EPE	ERM	Ambos	Teste	Validação
1	[140m-10-10-5]	0,9502902514	0,2547387718	466	562	308
2	[10-10-5]	0,9687024389	0,2592994411	3347	10000	252
3	[10-20-5]	0,9689940493	0,2595258139	717	10000	244
4	[10-30-5]	0,9697259472	0,2598024793	6116	10000	200
5	[20-10-5]	0,9548115236	0,2603774603	938	1038	691
6	[20-20-5]	0,9635908087	0,2625471865	2775	4358	317
7	[20-30-5]	0,9693200975	0,2628398801	1060	9827	472
8	[30-10-5]	0,9609548689	0,2615368844	1098	1148	542
9	[30-20-5]	0,9597091545	0,2610633526	669	845	290
10	[30-30-5]	0,9591376040	0,2604296815	750	1002	352

Percebe-se pela tabela acima que a rede multivariada [140m-10-10-5] apresentou resultados semelhantes a todas as outras redes desta mesma simulação, as quais sofreram variações quanto ao número de neurônios da camada de entrada e da camada intermediária. Podemos inferir que o conhecimento embutido na série histórica de variáveis climáticas nada pôde acrescentar àquele representado pela série de evapotranspiração.

Tabela 24 – Simulação 05 – Módulo 03

Rede	Estrutura	EPE	ERM	Ambos	Teste	Validação
1	[140m-20-10]	0,9848449844	0,2665281302	235	270	221
2	[060-20-10]	1,0056134583	0,2788697109	429	1521	249
3	[090-20-10]	0,9827587759	0,2759029388	267	253	281
4	[120-20-10]	0,9730304671	0,2697850375	257	267	248

Os resultados obtidos no módulo 03 da simulação 05 vêm confirmar as evidências apresentadas no módulo 02, que a série de variáveis climáticas apresentam componentes aleatórios tão ostensivos quanto a série de evapotranspiração.

Considerando os resultados obtidos nesses 3 módulos, chega-se a uma importante dedução, na qual entende-se não haver a necessidade de séries históricas completas com todas as variáveis exigidas pelo método de cálculo da evapotranspiração, seja ele qual for, bastando somente a própria série da evapotranspiração diária para utilizar as redes neurais na geração de previsões.

4. CONCLUSÕES E SUGESTÕES

4.1. CONCLUSÕES

- As redes neurais mostram-se aplicáveis à previsão da evapotranspiração de referência, uma vez que os menores erros obtidos para a previsão giram em torno de 0,8mm e 20% para a evapotranspiração de referência, quando utilizados os anos 1992 a 1997 no processo de aprendizagem.
- O software Smart Climate mostrou-se uma ferramenta prática e didática na criação, execução e avaliação das redes neurais. A implementação orientada a objetos do programa tornou-se uma excelente fonte de estudos e consultas para pesquisadores com pouco ou amplo conhecimento do assunto.
- Apenas 10 anos de dados históricos foram suficientes para realizar previsões da evapotranspiração de referência, igualando em importância as estações recentes que, apesar possuírem menor número de anos de série histórica, podem também ser utilizadas na previsão da evapotranspiração.
- Os valores para a taxa de aprendizagem e para o fator momentum que apresentaram melhores resultados foram 0,01, para ambos os termos.

- A utilização de um maior número de camadas intermediárias, bem como um maior número de neurônios de cada uma delas, não favoreceram melhorias nos resultados.
- As previsões para um conjunto maior de dias (até 10 dias) apresentaram resultados mais modestos que as previsões realizadas para um único dia, independente do número de dias definidos como entrada da rede.
- Não houve melhorias nos resultados utilizando-se a série histórica de variáveis climáticas ao invés da série histórica de evapotranspiração de referência.

4.2. SUGESTÕES

Software Smart Climate

- Para aumentar a eficiência na obtenção de bons resultados, utilizar algoritmos de inicialização dos pesos sinápticos, os quais através da diminuição do número de épocas possam gerar economia de tempo computacional.
- Como os cálculos realizados pelos neurônios de uma mesma camada são independentes, poder-se-ia utilizar os conceitos de programação concorrente para realizá-los simultaneamente. Para justificar este tipo de sofisticação, é imprescindível ter a disposição computadores com mais de um processador, para efetivamente extrair os benefícios da sobreposição de processamentos.
- Ao invés da orientação a objetos, implementar as estruturas de cálculo à maneira tradicional, usando arranjos e matrizes, visando aumentar a performance dos cálculos, economizando tempo computacional.
- Além de permitir finalização do treinamento pela execução de um número preestabelecido de épocas ou na obtenção de um erro mínimo, possibilitar sua interrupção quando o erro da parcela de dados de validação começar a

subir. Esta interrupção prematura do treinamento tende a evitar a ocorrência de sobre-adequação nas redes.

- Permitir o salvamento automático na obtenção de um melhor resultado ou na execução de um determinado número de épocas, evitando a perda de informações quando ocorrerem inesperados problemas computacionais.
- Criação de um arquivo DLL (dynamic link library) independente capaz de abrir os arquivos NNF, nos quais as redes neurais foram gravadas. Dessa forma, outros programas poderiam utilizar o conhecimento embutido nessas redes para gerar informações úteis a seus próprios modelos.

Dados Climáticos

- Utilizar maior ou menor número de anos. Lembrando que um número pequeno de anos compromete o “conhecimento” do clima, e um número grande inviabiliza o processamento computacional.
- Além da utilização do fator momentum na tentativa de fazer com que as redes neurais saiam de mínimo locais rasos em busca de outros mínimos da superfície de erro, existe a alternativa de incluir esporadicamente valores aleatórios (ruídos) para alguns sinais dos neurônios de entrada, durante o processo de treinamento. Pelos resultados obtidos, a série histórica da evapotranspiração demonstra já conter ruídos.
- Montar diferentes conjuntos de variáveis, como por exemplo, evapotranspiração e temperatura, ou evapotranspiração, temperatura e dia Juliano, ou ainda evapotranspiração, número de anos do último El Niño, etc...

Rede Neural

- Utilizar outras funções de ativação que não sigmóide logística.
- Utilizar outros algoritmos de correção de erros.
- Utilizar outros algoritmos de aprendizagem, como o Resilient BackPropagation, que não utilizam taxa de aprendizagem nem fator momentum.

- Utilizar um maior número de camadas intermediárias ou um maior número de neurônios nestas camadas.
- Utilizar maior número de épocas.
- Utilizar técnicas de pruning (podagem).
- Interromper o treinamento quando o erro da validação distanciar certa porcentagem do erro de teste.
- Dar maior ênfase aos anos recentes, repetindo-os um maior número de vezes durante o processo de treinamento.
- Utilizar algoritmos genéticos para estimar os parâmetros das redes neurais.

Outras

- A predição poderia utilizar dados climáticos recentes como nova parte aprendizado, visando inferir sobre o comportamento anual das variáveis climáticas e sobre a tendência de repetição de um dos anos da série. As redes neurais aproveitarão das previsões bem sucedidas para consolidar as previsões subseqüentes, da mesma forma que previsões mal sucedidas poderão ser utilizadas para ajustar as previsões futuras.
- Utilizar previsões mensais (um valor por mês) da evapotranspiração quando o objetivo for o dimensionamento de sistemas de irrigação.
- Utilizar previsões para dias anteriores e posteriores a um determinado dia de referência. Redes capazes de realizar boas previsões para dias antecedentes, teoricamente, deveriam bem prever os subseqüentes.
- Garantir a utilização de pelo menos um ano de El Niño e/ou La Nina no treinamento das redes.

5. REFERÊNCIAS BIBLIOGRÁFICAS

- ALTENDORF, C. T., ELLIOT, R. L., STEVENS, E. W., STONE, M. L. **Development and Validation of a Neural Network Model for Soil Water Content Prediction with Comparison to Regression Techniques.** Transactions of the ASAE – American Society of Agriculture Engineers, 1999. Vol. 42(3), p.p. 691-699.
- ANDRADE, L.C.M., DINIZ, H., CARVALHO, A. C. P. L. F., ANDRADE, M. G. **Previsão de Séries Temporais através de Redes Neurais Artificiais e Métodos Estocásticos.** In: SBRN, IV Simpósio Brasileiro de Redes Neurais, 1997. **Anais...** Sociedade Brasileira de Computação, Goiânia, GO, 1997. p.p. 13-17.
- BRAGA, A. P., LUDEMIR, T. B., CARVALHO, A. C. P. L. F. **Redes Neurais Artificiais, Teoria e Aplicações.** Editora LTC - Livros Técnicos e Científicos, Rio de Janeiro, RJ, 1a Edição, 2000. 323 p.
- CASTRO, L. N. de, VON ZUBEN, F. J. **Uma Alternativa Simples e Robusta para Inicialização de Pesos em Redes Neurais Multicamadas.** In: SBRN, V Simpósio Brasileiro de Redes Neurais, 1998. **Anais...** Sociedade Brasileira de Computação, Belo Horizonte, MG, 1998. Vol. 2, p.p. 97-101.

- CHAKRABORTY K., MEHROTRA, K., MOHAN, C. K., RANKA, S. 1992. **Forecasting the Behavior of Multivariate Time Series Using Neural Network.** Neural Networks, Vol. 5, No. 6, 1992. p.p. 961-970.
- CONDE, G. A. B, ABELÉN, A. J. **Modelo Orientado a Objetos de uma Rede Neural Artificial.** In: SBRN, IV Simpósio Brasileiro de Redes Neurais, 1997. **Anais...** Sociedade Brasileira de Computação, Goiânia, GO, 1997. p.p. 48-49.
- COSTA NETO, P. L. de O. **Estatística.** Editora Edgard Blücher Ltda, São Paulo, 1999. 264 p.
- CHRISTOFIDIS, D. **Caminhos Legais da Irrigação.** Trabalho apresentado no Painel III – Aspectos Gerais e Institucionais da Gestão dos Recursos Hídricos nas Américas, Encontro das Águas, Fortaleza, 1997.
- DINIZ, S. **Uso de Técnica Neural para o Reconhecimento de Comandos de Voz.** In: SBRN, IV Simpósio Brasileiro de Redes Neurais, 1997. **Anais...** Sociedade Brasileira de Computação, Goiânia, GO, 1997. p.p. 23-26.
- DINIZ, H., ANDRADE, L. C. M. de, CARVALHO, A. C. P. de L. F. de, ANDRADE, M. G. de A. **Previsão de Séries Temporais Utilizando Redes Neurais Artificiais e Modelos de Box e Jenkins.** In: SBRN, V Simpósio Brasileiro de Redes Neurais, 1998. **Anais...** Sociedade Brasileira de Computação, Belo Horizonte, MG, 1998. Vol. 2, p.p. 173-178.
- DOORENBOS, J., PRUITT, W. O. **Guidelines for Predicting Crop Water Requirements.** Irrigation Drain, FAO, Rome, Italy. 1977. Paper 24.
- EBERHART, R. C., DOBBINS, R. W. **Neural Network PC Tools – A Practical Guide.** Academic Press, Inc., San Diego, California. 1990. 414 p.
- ENSLEY, D., NELSON, D. E. **Extrapolation of Mackey-Glass Data Using Cascade Correlation.** Simulation, Vol. 58, No. 5, May 1992, p.p. 333-339.

- FAO Irrigation and Drainage Paper 56. **Crop Evapotranspiration – Guidelines for Computing Crop Water Requirements.** ALLEN, R. G., PEREIRA, L.S., RAES, D., SMITH, M., 1998. Food and Agriculture Organization of the United Nations, Rome, 1998, 309 p.
- HAYKIN, Simon, **Redes Neurais - Princípios e Prática.** Tradução: Paulo Martins Engel, Editora Bookman, Porto Alegre RS, 2^a Edição, 2000. 900 p.
- HILL, C., GRIFFITHS, W., JUDGE, G. **Econometria.** Tradução: Alfredo Alves de Farias, Editora Saraiva, São Paulo, 2000. 408 p.
- HOFFMANN, R., VIEIRA, S. **Análise de Regressão – Uma Introdução à Econometria.** – Editora HUCITEC, São Paulo, 2^a Edição, 1983. 379 p.
- KUMAR, M., RAGHUWANSHI, N. S., SINGH, R., WALLENDER, W. W., PRUITT, W. O. **Estimating Evapotranspiration using Artificial Neural Network.** In: Journal of Irrigation and Drainage Engineering, July/August 2002. p.p. 224-233.
- MELLO, J. L. P. **Análise de Sensibilidade dos Componentes da Equação de Panman-Montheith-FAO.** 1998. 79 f. Dissertação (Doutorado em Engenharia Agrícola) - Curso de Pós-Graduação em Engenharia Agrícola, Universidade Federal de Viçosa, Viçosa.
- MENDES FILHO, E. F., CARVALHO, A. C. P. de L. F. **Evolutionary Design of MLP Neural Network Architectures.** In: IV Brazilian Symposium on Neural Networks (SBNR 1997), IEEE - Institute of Electrical and Electronic Engineers, 1997. p.p. 58-65.
- NEVES, J., CORTEZ, P. **An Artificial Neural Network – Genetic Based Approach for Time Series Forecasting.** In: IV Brazilian Symposium on Neural Networks (SBNR 1997), IEEE - Institute of Electrical and Electronic Engineers, 1997. p.p. 9-13.

PESSOA, J. D. C., FREIRE, L. **Predição de Temperatura e Precipitação da Base de Dados de Estação Agrometeorológica da ESALQ - Escola Superior de Agricultura Luiz Queiroz - Usando Redes Neurais.** In: SBRN, V Simpósio Brasileiro de Redes Neurais, 1998. **Anais...** Sociedade Brasileira de Computação, Belo Horizonte, MG, 1998. Vol. 2, p.p. 269-272.

PRONI Tempo de Irrigar: Manual do Irrigante. PRONI - Programa Nacional de Irrigação. São Paulo Mater. 1987.

RUMELHART, D. E., HILTON, G. E., WILLIAMS, R. J. **Learning Representations by Back-Propagation Error.** Nature, 1986.

SALASSIER, B. **Manual de Irrigação.** Imprensa Universitária da Universidade Federal de Viçosa, Viçosa, 1995. 463.

SARMENTO, F. J. **Modelagem de Séries Hidrológicas Através de Redes de Neurônios.** RBRH – Revista Brasileira de Recursos Hídricos, 1996. Vol. 1, Número 2 Jul/Dez. p.p. 19-31.

SOARES, A. P., SOARES, A. P. **Previsão de Variáveis Meteorológicas através de Redes Neurais.** Agrosoft 1999. II Congresso da SBI-Agro, CD Anual.

VEMURI, V. R., ROGERS, R. D. **Artificial Neural Networks: Forecasting Time Series.** IEEE Computer Society Press, Los Alamitos, Califórnia. 1994.

Referências Bibliográficas conforme NBR-6023/2000, atualizada em maio de 2001

APÊNDICE I – MANUAL DO SMART CLIMATE

O programa Smart Climate é composto de apenas uma janela na qual é possível criar, editar e executar uma rede neural. Entende-se por execução de uma rede neural, o processo completo de aprendizagem, o qual é realizado através da alteração sistemática dos pesos sinápticos, durante as fases treinamento, teste e validação da rede.

Veja a figura abaixo.

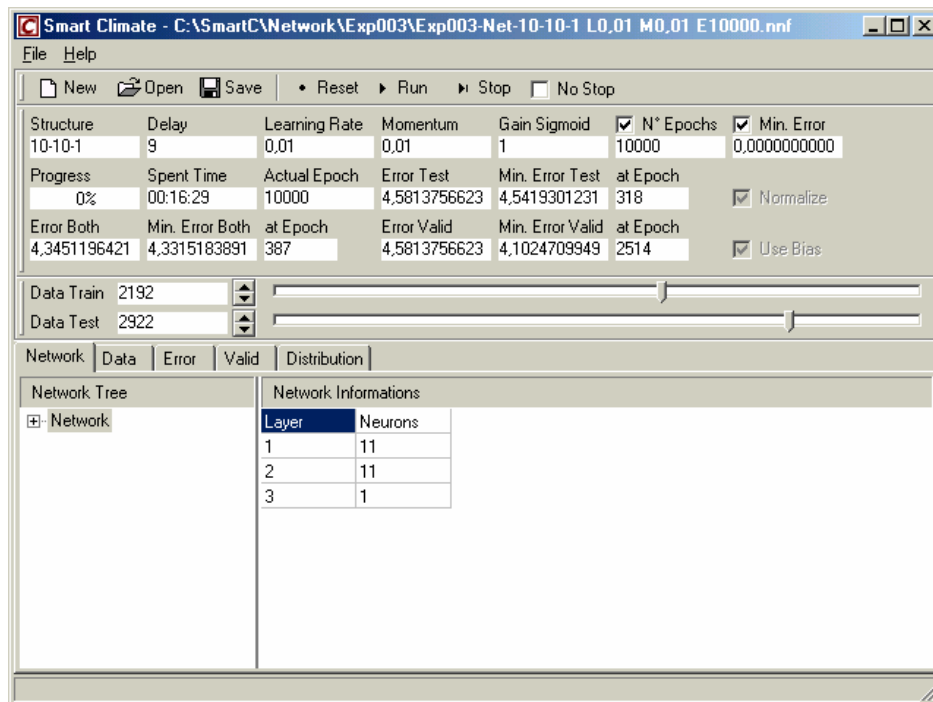


Figura 1 - Smart Climate

1. BARRA DE BOTÕES

- New Criar uma nova rede neural.
- Open Abrir uma rede neural anteriormente gravada em um arquivo extensão NNF (Neural Network File).
- Save Salvar a rede neural atualmente aberta.
- Reset Reinicializar a rede neural gerando pesos aleatórios para as sinapses.
- Run Executar a rede neural realizando aprendizado da rede.
- Stop Interromper a execução da rede neural.
- No Stop Quando marcado, impedir a interrupção da execução (executa mais rapidamente).

No menu principal encontra-se ainda a opção “SAVE AS” que permite a gravação das alterações da rede atual em outro arquivo NNF (Neural Network File). O software está preparado para interagir diretamente com Windows Explorer utilizando-se o duplo clique do mouse ou o arrastamento do arquivo.

2. CONFIGURAÇÕES DA REDE NEURAL

- Structure Estrutura da rede neural, número de neurônios por camada separados por “-”. A alteração na estrutura reinicializa a rede automaticamente.
- Delay Atraso dos dados de entrada da rede neural que são apresentados à primeira camada de neurônios.
- Learning Rate Taxa de aprendizado da rede.
- Momentum Momentum da rede
- Gain Sigmoid Ganho da função sigmoideal, função de ativação dos neurônios.
- N° Epochs Quando marcado, interrompe a execução da rede em um dado número de épocas.
- Min. Error Quando marcado, interrompe a execução da rede em um dado erro mínimo na fase de validação.

3. INFORMAÇÕES DE EXECUÇÃO

- Progress Indica a porcentagem de progresso na execução da rede.
- Spent Time Tempo gasto na execução da rede.
- Actual Epoch Época atual da execução da rede.

- Error Test Erro encontrado na fase de teste da rede na época atual.
- Min. Error Test Erro mínimo encontrado na fase de teste da rede.
- At Epoch Época na qual foi encontrado o erro mínimo de teste da rede.
- Error Valid Erro encontrado na fase de validação da rede na época atual.
- Min. Error Valid Erro mínimo encontrado na fase de validação da rede.
- At Epoch Época na qual foi encontrado o erro mínimo de validação da rede.
- Error Both Média do erro nas fases de teste e validação da rede na época atual.
- Min. Error Both Média do erro mínimo encontrado nas fases de teste e validação da rede.
- At Epoch Época na qual foi encontrada a média do erro mínimo das fases de teste e validação da rede.

4. DADOS DE ENTRADA

- Data Train Parcela dos dados utilizada na fase de treinamento.
- Data Test Parcela dos de dados utilizada na fase de teste.

5. PASTA NETWORK

Exibe a rede neural em formato árvore. Cada rede tem várias camadas (layers), cada camada tem vários neurônios (neurons), cada neurônio tem várias conexões (conexions) com os neurônios da camada anterior.

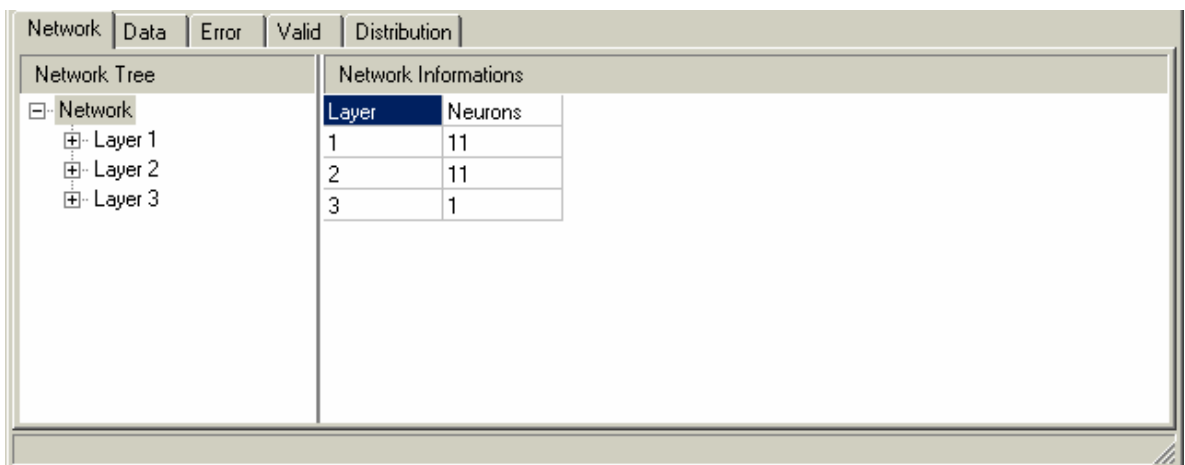


Figura 2 - Network

6. PASTA DATA

Permite a seleção de arquivos dos dados de entrada e saída da rede neural, arquivos estes no formato NND (Neural Network Data). Arquivos NND são arquivos textos nos quais são gravados os dados um por linha. O botão “FLE” abre o arquivo.

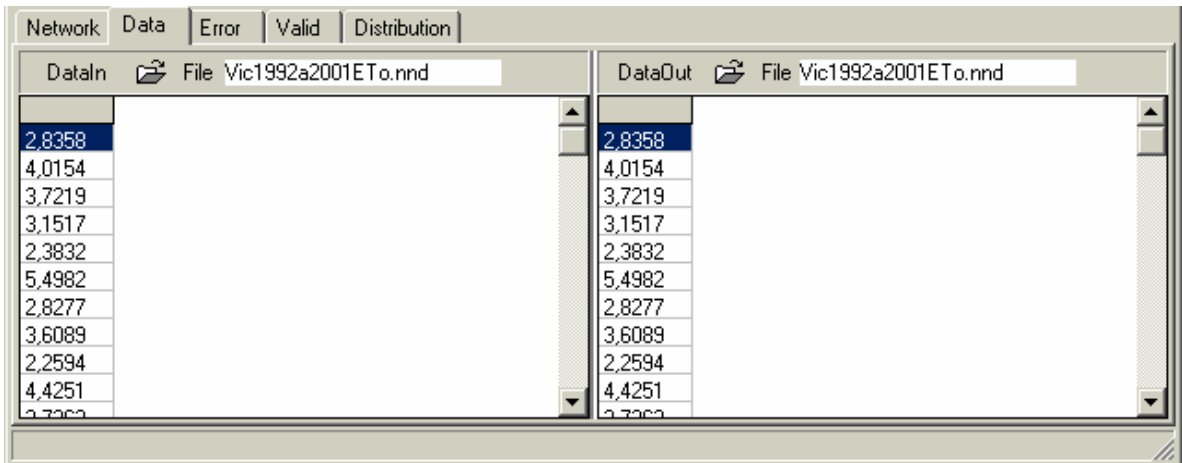


Figura 3 - Data

7. PASTA ERROR

Exibe o comportamento do erro de validação da rede para as últimas 100 épocas. Quando marcado “UPDATE ON EACH EPOCH”, para cada término de época, o erro encontrado na fase de validação é adicionado ao gráfico.

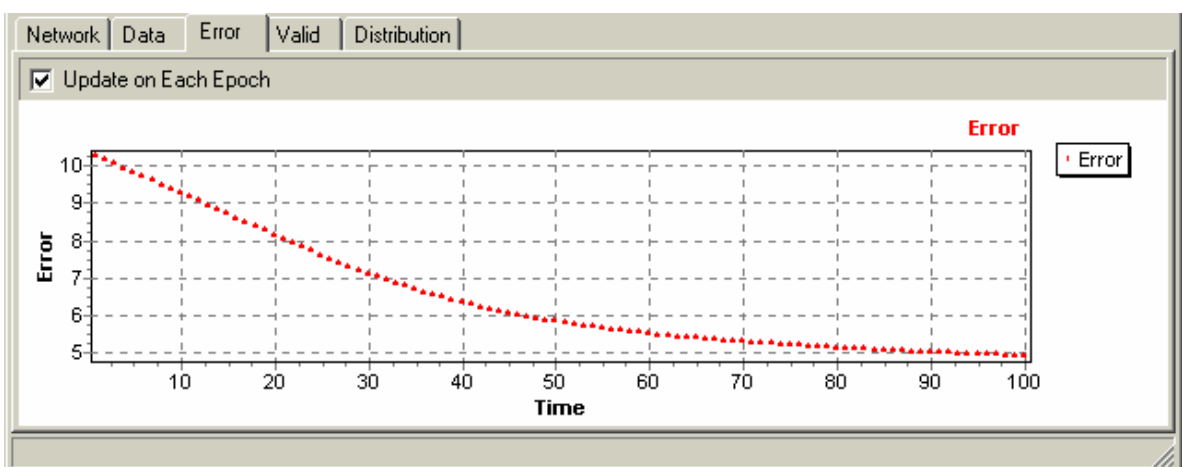


Figura 4 - Error

8. PASTA VALID

Exibe o gráfico dos dados de validação reais (azul) e dos dados gerados pela rede (vermelho). Um clique no botão VALID exibe o gráfico, o erro quadrático médio, o erro percentual médio e o coeficiente de correlação. Quando marcado “UPDATE ON EACH EPOCH”, o gráfico é atualizado para cada término de época.

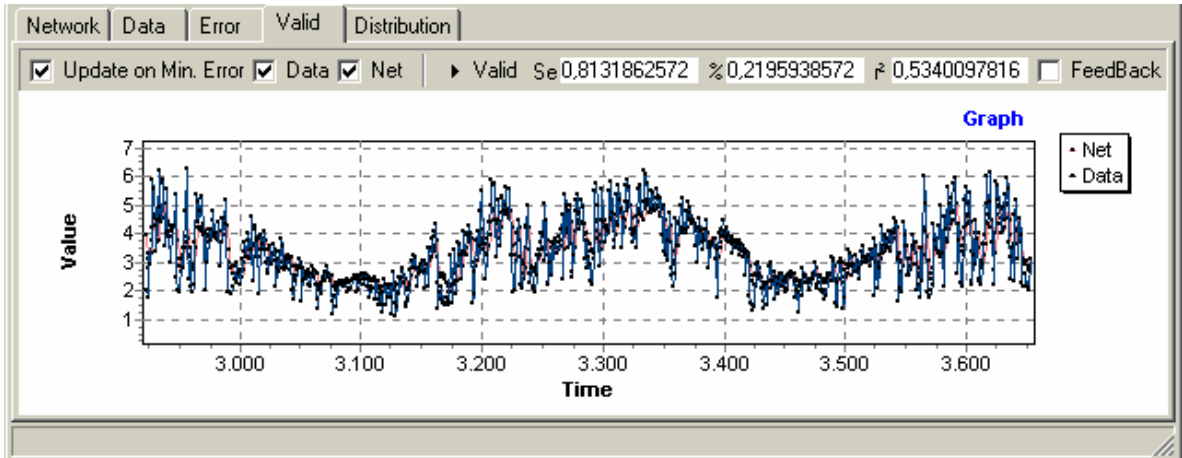


Figura 5 - Valid

9. PASTA DISTRIBUTION

Exibe a distribuição dos erros de validação, divididos nas porções desejadas (portions), clicando-se no botão “PORTION”.




Figura 6 - Distribution

10. PASTA ADJUSTMENT

Exibe o ajuste da previsão apresentando no gráfico a equação $y = x$, no eixo X os valores reais e no eixo Y os valores previstos.

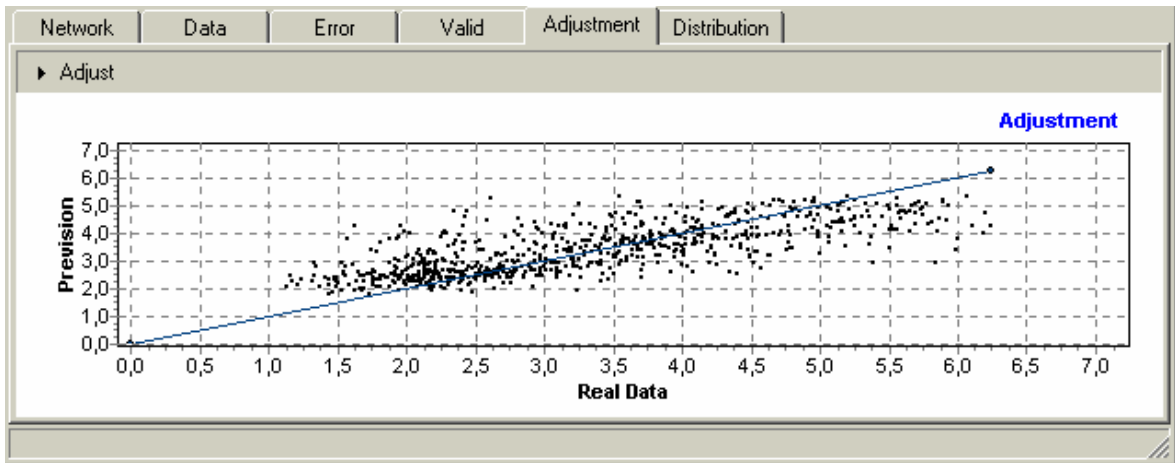


Figura 7 – Adjustment

11. SOBRE O SMART CLIMATE

O programa Smart Climate é parte integrante da dissertação de mestrado de Anderson Francisco da Silva pelo Departamento de Engenharia Agrícola da Universidade Federal de Viçosa.




Figura 8 – About Smart Climate