UNIVERSIDADE FEDERAL DE PELOTAS Faculdade de Meteorologia Graduação em Meteorologia



Trabalho de Conclusão de Curso

Relação entre as variáveis meteorológicas diárias e internações hospitalares de crianças na cidade de Santa Maria - RS

Gisele de Oliveira Vega

GISELE DE OLIVEIRA VEGA

Relação entre as variáveis meteorológicas diárias e internações hospitalares de crianças na cidade de Santa Maria - RS

Trabalho acadêmico apresentado ao Curso de Graduação em Meteorologia, da Faculdade de Meteorologia, da Universidade Federal de Pelotas, como requisito parcial à obtenção do título de Bacharel em Meteorologia.

Orientador: Prof. Dr. Fabrício Pereira Härter

Coorientador: Prof. Dr. Anderson Spohr Nedel

Dados de catalogação na fonte: Maria Beatriz Vaghetti Vieira – CRB-10/1032 Biblioteca de Ciência & Tecnologia - UFPel

V422r Vega, C

Vega, Gisele de Oliveira

Relação entre as variáveis meteorológicas diárias e internações hospitalares de crianças na cidade de Santa Maria - RS / Gisele de Oliveira Vega. – 57f. : il. – Monografia (Conclusão de curso). Graduação em Meteorologia. Universidade Federal de Pelotas. Faculdade de Meteorologia. Pelotas, 2014. – Orientador Fabrício Pereira Härter; co-orientador Anderson Spohr Nedel.

1.Meteorologia. 2. Índices biometerológicos. 3. Doenças respiratórias. 4. Internação hospitalar. I.Härter, Fabrício Pereira. II.Nedel, Anderson Spohr. III.Título.

CDD: 551.540981659

Gisele de Oliveira Vega

Relação entre as variáveis meteorológicas diárias e internações hospitalares de crianças na cidade de Santa Maria - RS

Trabalho de Conclusão de Curso aprovado, como requisito parcial, para obtenção do grau de Bacharel em Meteorologia, Faculdade de Meteorologia, Universidade Federal de Pelotas.

Data da Defesa: 13 de junho de 2014

Banca examinadora:

Prof. Dr. Fabrício Pereira Härter (Orientador)

Doutor em Computação Aplicada pelo Instituto Nacional de Pesquisas **Espaciais**

Prof. Dr. Anderson Spohr Nedel

Doutor em Meteorologia pela Universidade de São Paulo

Prof. Dr. Julio Renato Quevedo Marques

Doutor em Fitotecnia pela Universidade Federal do Rio Grande do Sul



Agradecimentos

Agradeço a Deus, por ter me dado força e saúde para superar as dificuldades.

A minha família, que sempre acreditou e investiu em mim, principalmente aos meus pais. Mãe, sua dedicação e confiança em mim, me deram, em todos os momentos, a esperança para seguir em frente. A você pai, que sempre me passou segurança e a certeza que jamais estive sozinha. Obrigada pelo amor, incentivo e apoio incondicional.

Ao meu namorado Daniel, pessoa com quem amo compartilhar a minha vida. Obrigada pelo carinho, amor, atenção, paciência, e por sua imensa capacidade de me acalmar nos momentos em que mais precisei.

As grandes amizades que aqui conquistei. Simone, Juliana, Jéssica, Bruno, Sandro e Anderson, agradeço por cada momento em que passamos juntos, pelas alegrias, pelas tristezas, dores, risadas compartilhadas. Com vocês, as madrugadas de estudos nunca foram só de estudos, as pausas entre um exercício ou outro (ou todos) melhorou tudo que eu tenho produzido na vida. Jamais me esquecerei de vocês.

Ao professor Fabrício, pela paciência na orientação que tornou possível a conclusão desse trabalho. Aos professores Anderson e Julio que sempre tiveram disponibilidade e paciência para me ajudar em momentos de dúvidas.

E a todos que de forma direta ou indireta, fizeram parte da minha formação.

Resumo

VEGA, Gisele. Relação entre as variáveis meteorológicas diárias e internações hospitalares de crianças na cidade de Santa Maria - RS. 2014. 57f. Trabalho de Conclusão de Curso (Graduação) — Curso de Graduação em Meteorologia. Universidade Federal de Pelotas, Pelotas.

Os problemas respiratórios representam uma das principais causas nas internações hospitalares em crianças de todo Brasil. O conhecimento da demanda por internações futuras pode auxiliar os hospitais a gerenciarem e administrarem da melhor maneira seus recursos, agindo no sentido de mitigar possíveis adversidades do tempo/clima. Dessa forma, o objetivo desse trabalho foi desenvolver um modelo estatístico que permita o usuário prever se determinadas variações no tempo implicam em internações hospitalares por Influenza/Pneumonia (IP), Afecção das Vias Aéreas Superiores (AVAS) e Afecção das Vias Aéreas Inferiores (AVIS) para a cidade de Santa Maria - RS, para um período de sete anos (2002 a 2009) para os meses de junho, julho e agosto (inverno). Os dados utilizados foram variáveis meteorológicas diárias de temperatura do ar (mínima, máxima e média), umidade relativa do ar (mínima, máxima e média), pressão média, precipitação e velocidade do vento (média), obtidos através da Estação Meteorológica Automática do Instituto Nacional de Meteorologia (INMET) de Santa Maria e os dados de morbidades obtidos através dos registros das Autorizações de Internação Hospitalar (AIH). Além disso, os índices biometeorológicos de Temperatura Efetiva em Função do Vento e as defasagens em dias (lags), também foram utilizadas para a obtenção dos resultados. Foram utilizadas análises de Regressões Lineares Múltiplas, Análises de Componentes Principais e uma metodologia baseada em Rede Neural Artificial Perceptron de Múltiplas Camadas (PMC) para que as mesmas extraiam informações de um conjunto de variáveis meteorológicas associadas a doenças respiratórias que causam internações hospitalares. Com base nos resultados observados, pode-se avaliar que os modelos estatísticos gerados não responderam de forma satisfatória na estimativa das internações hospitalares por doenças respiratórias, porém foi dado um importante passo nesta direção.

Palavras chaves: internação hospitalar, doenças respiratórias, índices biometeorológicos.

Abstract

VEGA, Gisele. 2014. The daily meteorological variables and their relation with hospitalizations in children in Santa Maria - RS. 57p. Final examination – Faculty of Meteorology. Federal University of Pelotas, Pelotas.

Respiratory problems represent one of the main causes on the child hospitalizations from all over Brazil. The knowledge of the demand by future hospitalizations can help the hospitals to manage and administrate the resources of the best way, acting in order to mitigate possible weather/climate adversities. In this way, the objective of this study was to develop a statistic model which allows the user to forecast if certain weather changes imply in hospitalizations by Influenza/Pneumonia (IP), Upper Airways Diseases (AVAS) and Lower Airways Diseases (AVIS) to the city of Santa Maria-RS, between a period of seven years (2002 to 2009) to the months of June, July and August (winter). The used data were the daily meteorological variables of air temperature (minimum, maxim and average), relative air humidity (minimum, maxim and average) and wind speed (average), obtained through the Automatic Weather Station of the National Institute of Meteorology (INMET) of Santa Maria, and the morbidities data obtained through the records of Hospital Admissions Authorizations (AIH). Were used analysis of Multiple Linear Regressions, Main Components Analysis and a methodology based in Artificial Neural Network Percepton of Multiple Layers (PMC), so that the same extract information from a set of meteorological variables associated to respiratory diseases which causes hospitalizations. Based in the observed preliminary results, can be assessed that Statistical Models generated did not responded satisfactorily in the estimation of hospitalizations by respiratory diseases, although this work represents a first step in this way.

Keywords: Hospitalizations, Respiratory Diseases, Biometeorological Index.

Lista de Figuras

Figura 1 – Localização de Santa Maria – RS Fonte: http://confins.revues.org/747711
Figura 2 - Ilustração da Rede Neural aplicada nesse trabalho29
Figura 3: Significância em percentual para cada análise de componente principal para junho37
Figura 4: Análise das variáveis da primeira componente principal para junho38
Figura 5: Análise das variáveis da segunda componente principal para junho39
Figura 6: Significância em percentual para cada análise de componente principal para julho40
Figura 7: Análise das variáveis da primeira componente principal para julho41
Figura 8: Análise das variáveis da segunda componente principal para julho42
Figura 9: Significância em percentual para cada análise de componente principal para agosto43
Figura 10: Análise das variáveis da primeira componente principal para agosto44
Figura 11: Análise das variáveis da segunda componente principal para agosto45
Figura 12: Erro de treinamento da RPMC46

Lista de tabelas

Tabela	1	- Número de internações por Influenza/Pneumonia observadas (IP) e número de internações por Influenza/Pneumonia estimadas (IP')
Tabela	2	- Número de internação por Afecção das Vias Aéreas Superiores observadas (AVAS) e número de internação por Afecção das Vias Aéreas Superiores (AVAS')
Tabela	3 -	Número de internação por Afecção das Vias Aéreas Inferiores observadas (AVIS) e número de internação por Afecção das Vias Aéreas Inferiores estimadas (AVIS')
Tabela	4	- Variáveis mais significativas da primeira análise de componentes principais para o mês de junho38
Tabela	5	- Variáveis mais significativas da segunda análise de componentes principais para o mês de junho39
Tabela	6	- Variáveis mais significativas da primeira análise de componentes principais para o mês de julho41
Tabela	7	- Variáveis mais significativas da segunda análise de componentes principais para o mês de julho42
Tabela	8	- Variáveis mais significativas da segunda análise de componentes principais para o mês de agosto44
Tabela	9	- Variáveis mais significativas da segunda análise de componentes principais para o mês de agosto45

Lista de abreviaturas e siglas

°C Graus Celsius

ACP Análise de Componentes Principais
AIH Autorizações de Internação Hospitalar
AVAI Afecções das Vias Aéreas Inferiores
AVAS Afecções das Vias Aéreas Superiores

CO Monóxido de Carbono CTH Conforto Térmico Humano

h hora

INMET Instituto Nacional de Meteorologia

IP Influenza e Pneumonia

IRA Infecção Respiratória Aguda

IVAI Infecções das Vias Aéreas Inferiores

Km Kilômetro m metro

MBCS Modelo Brasileiro de Clima e Saúde

MP₁₀ Material Particulado

MRLM Modelo de Regressão Linear Múltipla

MT Mato Grosso

NO_x Número de Oxidação

O₃ Ozônio

OMS Organização Mundial de Saúde

RH Umidade Relativa

RLM Regressão Linear Múltipla RNA Redes Neurais Artificiais

RPMC Rede Percepton de Múltiplas Camadas

SO2 Dióxido de Enxofre RS Rio Grande do Sul

SUS Sistema Único de Saúde TE Temperatura Efetiva

TE_v Temperatura Efetiva em função do Vento

Sumário

Introdução	13
Revisão de Literatura	15
2.1 Região de Estudo	15
2.2 Importância do estudo	16
2.3 Doenças respiratórias em crianças	17
Metodologia	22
3.1 Dados	22
3.2 Cálculo do índice de conforto térmico	23
3.3 Regressão Linear Multivariada	24
3.4 Análises de Componentes Principais	25
3.5 Redes Neurais	27
3.5.1 Rede Perceptron de Múltiplas Camadas (RPMC)	27
Resultados e Discussões	32
4.1 Modelo de Regressão Linear Múltipla (MRLM)	32
4.2 Modelo de Regressão Linear Múltipla (MRLM) para AVAS	34
4.3 Modelo de Regressão Linear Múltipla (MRLM) para AVAI	35
4.4 Análises de Componentes Principais	36
4.4.1 Análise de Componentes Principais para o mês de Junho	para IP
 	36
4.4.2 Análise de Componentes Principais para o mês de Julho	40

	4.4.3 Análise de Componentes Principais para o mês de Agosto para	ı IP
		.43
	4.5 Rede Neural Perceptron de Múltiplas Camadas	
Co	onclusão	.49
Re	eferências	.51

Introdução

É intuitivo que o desenvolvimento e propagação de sistemas que causam mudanças nas variáveis meteorológicas em baixos níveis da atmosfera, tais como frentes frias e quentes, massas de ar, linhas de instabilidade, geadas, sistemas de alta e baixa pressão, cristas, cavados e vórtices ciclônicos, entre outros, estão altamente correlacionados com surgimento (desenvolvimento) de doenças do sistema respiratório e cardiovascular em seres humanos e também em animais.

As doenças respiratórias têm uma grande contribuição para o índice de morbidade e mortalidade na infância em países desenvolvidos, bem como em países em desenvolvimento. A estimativa é de que 25% a 33% do total das mortes observadas nos primeiros cinco anos de vida sejam ocasionadas por infecções respiratórias agudas (CARDOSO, 2007).

O tempo e o clima podem ter influência na ocorrência de episódios respiratórios no ser humano, dessa forma, a maior parte das doenças respiratórias podem ser provocadas, estimuladas ou até mesmo causadas por fatores meteorológicos (TROMP, 1980).

Partindo desse pressuposto, quantificar e entender as causas e efeitos desta relação é de importância fundamental para as atividades socioeconômicas.

Segundo Nedel (2008), no Brasil, o estudo das Infecções Respiratórias Agudas merece atenção especial, principalmente em crianças menores de cinco anos de idade, pois, por ser a parcela da população mais suscetível, são registradas altas taxas de morbidade (internações hospitalares).

Há uma grande quantidade de trabalhos na literatura, associando variações no tempo, clima e poluição atmosférica com internações hospitalares. Entretanto, os autores não apresentam muitas propostas de modelos, sejam estocásticos ou dinâmicos, quantificando o número de internações.

Portanto a realização de um estudo que envolva essas mudanças nas variáveis meteorológicas com as morbidades através de um modelo estatístico, é de grande importância, pois auxiliará os hospitais da região a se organizarem melhor para receber a demanda de internações em picos gerados pelas condições do tempo.

O objetivo deste trabalho é encontrar um modelo estatístico que permita identificar e possivelmente quantificar a relação entre mudanças bruscas de temperatura e umidade no inverno e internações hospitalares causadas por influenza e pneumonia.

Para tal, aborda-se o problema através de duas metodologias, a saber: Redes Neurais Artificiais (RNA) (HAYKIN, 2004) e Regressão Linear Múltipla (WILKS, 2006). Esta metodologia, pose ser aplicada a qualquer localidade cujos dados de internação hospitalar e registros meteorológicos estejam disponíveis. Entretanto, este trabalho é aplicado para a cidade de Santa Maria – RS.

Uma vez que se consiga relacionar e até mesmo quantificar estas relações, têm-se os seguintes objetivos específicos:

- Identificar picos de internação para auxiliar gestores hospitalares na disponibilidade de leitos;
- 2) Obter um modelo valido para qualquer localidade;
- Prever o número e pico de internações através de variáveis meteorológicas obtidas por modelo numérico de previsão de tempo.

Revisão de Literatura

2.1 Região de Estudo

Esse estudo foi realizado em Santa Maria – RS, localizada na depressão central do Rio Grande do Sul e devido a sua localização geográfica, é denominada o município coração do Rio Grande do Sul, localizado entre as coordenadas de longitude 53º 48' 25"O, de latitude 29º 41' 03"S e com latitude média de 113m acima do nível do mar. Segundo a classificação climática de Köppen (1948), Santa Maria possui um clima do tipo Cfa – subtropical úmido - com chuvas bem distribuídas durante todo o ano e com temperaturas médias em aproximadamente 19,2°C, podendo ter uma grande variação com mínimas chegando até em 3°C e as máximas em 40°C (EMBRAPA,2013). Uma das características da cidade é o vento Norte, que é muito forte e pode chegar a 100 km/h. (Fig. 1).

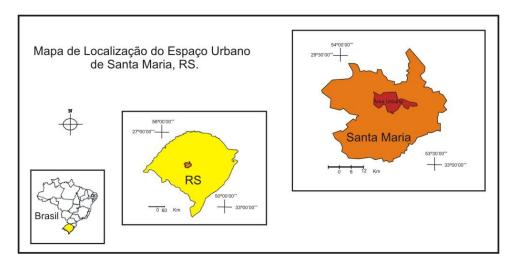


Figura 1: Localização de Santa Maria

Fonte: MELARA, Eliane (2012)

2.2 Importância do estudo

A primeira referência sobre a influência do ambiente na saúde da humanidade a diferentes condições atmosféricas foi dita por Hipócrates, considerado o "pai da medicina" por muitos, em 400 a.C. Em sua publicação chamada "Aires, aguas y lugares", ele cita que:

"Quem deseja estudar corretamente a ciência da medicina, deverá proceder da seguinte maneira. Primeiro, deverá considerar os efeitos que cada estação do ano pode produzir, pois as estações não são todas iguais".

Além disso, ele comenta que a forma que cada indivíduo se comporta na sua rotina, ou seja, o jeito de viver, a alimentação, a estrutura física, o lugar que habita, precisam ser observados. Porém, as mudanças antropogênicas, provocadas pela urbanização interferem na saúde humana, desse modo, também deve ser levada em consideração (GONÇALVES et al., 2007).

As variáveis meteorológicas, como temperatura, umidade do ar e velocidade do vento afetam diretamente no conforto térmico humano, ou seja, afetam diretamente no comportamento do ser humano (COELHO, 2007).

Fanger (1970) definiu o conforto térmico como "a condição da mente que expressa a satisfação com o ambiente" ou a sensação de neutralidade térmica experimentada pelo ser humano em um determinado ambiente. No entanto, essa condição, não é precisa e varia de pessoa para pessoa conforme a idade, gênero, tipo de vestimenta e também devido às variáveis ambientais. Um exemplo a ser levado em consideração, são as crianças que, por sua vez, podem sofrer mais, devido ao pequeno volume e grande área superficial, e pelo fato de ter um sistema termorregulador ainda deficiente, perdem muito calor para o ambiente (NEDEL, 2008).

Coelho (2007) comenta que, a partir da revolução industrial, a influência desastrosa do homem e a natureza ficaram mais perceptíveis, pois essa interação ocorreu de forma natural e predatória, ocasionando a poluição. Levando em conta o fato de precisarmos respirar para sobreviver, a poluição é a alteração mais sentida pela população. Essa agressão é evidente principalmente em grandes centros urbanos, como São Paulo, por exemplo, que pode ser considerada uma das cidades mais poluídas do mundo.

Segundo a Organização Mundial da Saúde (OMS), em diversos lugares do mundo a saúde humana tem sido influenciada pelas mudanças climáticas. Muito frio seguido de muito calor ou ao contrário, temporais, enchentes entre outros problemas causados por eventos naturais provocados por essas mudanças climáticas têm afetado diretamente a saúde da população. Além disso, foi apontado que 8% do total de mortes em países desenvolvidos e 5% em países em desenvolvimento são ocasionados por doenças respiratórias.

Dentre vários fatores determinantes para o aumento no número das doenças respiratórias e a gravidade dessas internações, os que desempenham um papel de máxima importância, são os fatores ambientais, pois mudanças bruscas de tempo, por exemplo, causam uma piora na qualidade do ar respirado, principalmente quando o local tratado encontra-se sob influência de sistemas meteorológicos, como massas de ar frio e seco, dificultando a dispersão dos poluentes na atmosfera (NEDEL, 2008).

No Brasil, as doenças respiratórias agudas e crônicas ocupam posição de destaque, pois estão entre as principais causas de internação no Sistema Único de Saúde – SUS, em 2001, atingiram o segundo lugar, sendo responsáveis por cerca de 16% de todas as internações (MINISTÉRIO DA SAÚDE, 2001).

2.3 Doenças respiratórias em crianças

As doenças respiratórias, especialmente na infância, representam um grande problema de saúde pública. As causas dessas doenças podem ser infecciosas (por vírus e bactérias), como gripes e pneumonias, ou não infecciosa como asma e bronquite (CARDOSO, 2007).

A OMS contabilizou, em 1995, 4,3 milhões de crianças com idade inferior a cinco anos morreram por doenças respiratórias agudas nos países em desenvolvimento.

Lin (1999) fez uma relação entre as doenças respiratórias em crianças e os poluentes atmosféricos na cidade de São Paulo, notaram que houve um aumento de 20% no atendimento emergencial por doenças respiratórias.

Moura et al. (2008) realizaram um estudo em Jacarepaguá – Rio de Janeiro, entre abril de 2002 a março de 2003, avaliando a relação entre a poluição do ar e os

efeitos respiratórios agudos em crianças. Somente o O_3 apresentou resultado positivo e estaticamente significativo para os atendimentos de emergência por queixas respiratórias e para os atendimentos causados por sintomas nas vias aéreas inferiores. O efeito ocorreu no mesmo dia da exposição (sem defasagem). Não foi observado resultado significativo com os outros poluentes atmosféricos.

As doenças respiratórias contribuem para alta proporção de morbidade e mortalidade na infância tanto em países desenvolvidos como em países que estão em desenvolvimento. Os custos com o tratamento das infecções graves na população infantil do nosso país são elevados, chegando a cerca de R\$ 17 bilhões (anualmente) ao Sistema Único de Saúde (SUS), sendo que aproximadamente 10 bilhões gastos com esses pacientes acabam chegando a óbito (MINISTÉRIO DA SAÚDE, 2008), o que acarreta em um grande comprometimento no orçamento público.

Observando a importância do tempo/clima sobre a sociedade, muitos trabalhos analisam o comportamento das variáveis meteorológicas com a saúde humana, conforme as referências a seguir.

A fim de analisar o conforto térmico humano ao longo do ano de 1989 na cidade de São Paulo, e avaliar a influência de um ou mais fatores sobre o ser humano (número de internações hospitalares diárias por doenças respiratórias e poluição atmosférica), Maia (2002) utilizou cinco índices biometeorológicos, experimentados para uma determinada amostra de uma população. Os resultados obtidos mostraram que as internações médias hospitalares estavam associadas aos parâmetros meteorológicos, níveis de poluição, bem como aos índices de conforto térmico.

Braun (2003) analisou o conforto térmico humano na cidade de São Paulo durante o período de 1996 a 2000 e também verificou o efeito dos índices biometeorológicos, das variáveis meteorológicas e dos níveis de poluição atmosférica por doenças cardiovasculares em pessoas com mais de 65 anos. Os resultados apresentaram o período do verão como o de influência para a condição de estresse em função do calor e que as condições térmicas relacionadas ao frio, foram responsáveis por 45% dos óbitos representados pelos índices TE e TEV, enquanto que, as relacionados ao calor foram responsáveis por 24% das mortes.

Coelho (2007) realizou um estudo na cidade de São Paulo no período de 3 anos (1997 a 2000) com a intenção de obter um modelo estatístico capaz de prever

as internações hospitalares usando dados de índices biometeorológicos e dados de poluição do ar. A metodologia aplicada se baseou em uma estatística de Regressão de Poisson e em uma Análise de Componentes Principais (ACP). Através dessa metodologia, encontraram-se modelos estatísticos que fossem capazes de prever aproximadamente as internações hospitalares por doenças respiratórias chamados de MBCS (Modelo Brasileiro de Clima e Saúde). Os dados de internação foram divididos por categorias, mais especificamente 3 categorias, estas seriam, AVAS (Afecções Vias Aéreas Superiores), AVAI (Afecções das Vias Aéreas Inferiores) e IP (Influenza e Pneumonia). Com relação aos índices de conforto térmico humano, foram obtidos com as variáveis meteorológicas. Os resultados mostraram associação entre AVAS e SO2, CO (sem defasagem) e com o índice biometeorológico TEv4 (com 4 dias de defasagem) e nota-se que apesar da baixa concentração do SO2 o mesmo causa o aumento na internação. No que se diz a respeito ao AVAI, ocorreu uma associação entre os poluentes Material Particulado (MP_{10}) , O_3 (sem defasagem) e TEv_4 (com 3 dias de defasagem). Por fim, foi analisado que MP₁₀ e TEv₄ estavam ligadas com as internações por IP. Esses modelos apresentaram um erro médio de 15% para AVAS, 30% para AVAI e 44% para IP. Foi concluído que o Modelo Brasileiro de Clima e Saúde pode ser utilizado para a previsão de internações.

Cardoso (2007) elaborou um estudo no qual relacionava as condições do micro clima de ambientes interiores com as doenças respiratórias em crianças recém nascidas na cidade de São Paulo. Analisou as condições higrotérmicas (que seria a ausência de desconforto térmico) dos domicílios, feita por medidas internas de temperatura do ar e da umidade relativa do ar nas residências. Logo após, efetuou a comparação com prognósticos médicos. Os resultados indicaram um aumento significativo na ocorrência de doença respiratória do trato aéreo inferior em crianças (IVAI) associado ao aumento da variação da temperatura interna ao domicílio. Por fim, foi observado que domicílios com estruturas construtivas leves não protegiam seus moradores da variação climática externa, sendo assim, as crianças sofriam por problemas respiratórios.

Nedel (2008) realizou um estudo em crianças recém-nascidas na cidade de São Paulo, no qual relacionou as variáveis meteorológicas e a morbidade respiratória (internação hospitalar por doenças respiratórias). A partir dos resultados, pode-se concluir que a maioria dos problemas estava relacionada à queda da

temperatura e ao aumento da umidade relativa do ar. E ao tratar sobre a relação do conforto térmico interno, foi observado um alto estresse devido ao calor nas tardes de verão, e um elevado estresse por frio nas manhãs de inverno, principalmente nos dias mais frios e secos.

A fim de relacionar as mortalidades por doenças respiratórias em crianças na cidade de São Paulo e sua interação com a umidade do ar, temperatura e os poluentes PM₁₀, CO, O₃, NO_x e SO₂, Saldiva (1994) encontrou uma associação significativa entre a taxa de mortalidade por doenças respiratórias e os níveis de NO_x.

Um estudo realizado por Botelho et al. (2003) na cidade de Cuiabá – MT tinha como finalidade verificar uma possível associação de alguns fatores ambientais, com a necessidade de tratamento hospitalar em crianças diagnosticadas com Infecção Respiratória Aguda (IRA), visto que a hospitalização é considerada um indicador de gravidade de IRA. Foram utilizados prontuários de atendimento do Pronto Socorro Municipal de Cuiabá de crianças menores que cinco anos, de ambos os sexos. Foram analisados em dois períodos climáticos: seco (maio a outubro) e chuvoso (novembro a abril). As variáveis relacionadas foram: temperatura, umidade relativa do ar, número de focos de queimadas. Como resultado foi observado que as internações ocasionadas por IRA em crianças menores que cinco anos foi alta e com maior ocorrência nos períodos secos. Além disso, pode-se observar que a baixa umidade relativa do ar está associada com a maior necessidade de hospitalização das crianças estudadas.

Diversas pesquisas indicam que certas massas de ar podem ser fundamentais e responsáveis por aumentos significativos nas entradas hospitalares por doenças respiratórias, como por exemplo, a asma. (NEDEL, 2008). Partindo dessa linha de raciocínio, Jamason et al. (1997) estudaram a relação entre asma e variações atmosféricas na região metropolitana da cidade de Nova Iorque. A metodologia consistiu em isolar massas de ar homogêneas do ponto de vista de suas características termodinâmicas e relacioná-las com número de internações por asma, durante a madrugada, nos hospitais da região de estudo. Os autores encontraram alta correlação entre internação por asma e a entrada de certas massas de ar. Esta relação varia sazonalmente, sendo o inverno e o outono as estações de maior correlação. Os autores encontraram também, alta correlação

entre poluentes atmosféricos e entradas de massas de ar na primavera e no verão, enquanto no inverno e outono esta correlação foi baixa.

Kassomenos et al. (2007), estudaram os efeitos das massas de ar sobre a cidade de Atenas, Grécia a curto prazo. Foram classificados os tipos de massas de ar que atuavam sobre a cidade e, logo após, compararam com os dados de mortalidade. Pode-se observar que os elevados índices de mortalidade diária foram caracterizados, no verão, por massas de ar com alta umidade.

Em Buenos Aires, na Argentina, RUSTICUCCI et al. (2001), relacionaram as condições do tempo e a entrada dos pacientes em salas de emergência hospitalar nos períodos de verão e inverno. Os resultados apresentaram que no período de inverno, ocorreu um aumento de 16,7% nas entradas à emergência por diversos tipos de complicações (respiratória, cardiovascular e dor no peito, infecções, neurológica e psicopatológica, entre outras...), enquanto que, no verão, houve um aumento elevado nas complicações digestivas, de pele e também alérgicas. Obtiveram uma maior admissão por problemas respiratórios em um dia após o pico da temperatura do ponto de orvalho. Já alguns problemas digestivos e abdominais estavam diretamente relacionados ao aumento na temperatura do ar, na temperatura do ponto de orvalho e na diminuição da pressão atmosférica durante o inverno.

Metodologia

3.1 Dados

Para a realização desse estudo, foram analisadas todas as internações por afecções das vias aéreas tanto inferiores (AVAI) como superiores (AVAS), influenza e pneumonia (IP) em crianças de até cinco anos do Hospital Universitário de Santa Maria. A princípio foram feitas correlações para todos os meses de todos os anos estudados (2002 a 2009). Porém, destaca-se que os maiores picos de internação ocorrem nos meses de inverno para IP, AVAS e AVAI. Dessa forma, optou-se utilizar apenas os dados dos meses de junho, julho e agosto de todos os anos para a realização das Análises de Componentes Principais.

Esses dados são registros das Autorizações de Internação Hospitalar (AIH) de hospitais públicos que atendem à parcela da população que não possuem planos de saúde privados.

Informações sobre a temperatura do ar (média, máxima e mínima), umidade (média, máxima e mínima) e velocidade do vento foram obtidas junto à Estação Meteorológica Automática do Instituto Nacional de Meteorologia (INMET) de Santa Maria.

Os dados meteorológicos e os dados de morbidade foram ajustados a uma função de distribuição normal. Foram introduzidos no software R, pois como possuem unidades físicas diferentes, aplicou-se uma normalização para que a influência da localização e extensão do conjunto de dados fosse removida. Dessa forma, esse processo converte as observações dos dados principais em um fator padronizado, onde a média é igual a zero e o desvio padrão é igual a um.

3.2 Cálculo do índice de conforto térmico

O Conforto Térmico Humano (CTH) foi medido por meio de índices de conforto conhecidos como Índices Biometeorológicos. Os índices são divididos em nove faixas, variando desde muito frio até muito quente. Esse critério é conhecido como "critério de Fanger" e foi obtido como resultado de medições das respostas fisiológicas do ser humano quando é exposto ao calor ou frio.O índice utilizado nesse estudo foi o índice de Temperatura Efetiva com o Vento (TE_V).

Proposto por Suping et al. (1992), esse índice é expresso pela expressão matemática a seguir:

$$TE_{v} = 37 - \frac{(37-T)}{\left[0.68 - 0.0014RH + \frac{1}{1.76 + 1.4v}, \frac{1}{0.75}\right]} - 0.29T \left(1 - \frac{RH}{100}\right)$$
 Eq. 1

Onde:

TE_v - é temperatura efetiva em função do vento em °C

T - é a temperatura do ar em °C

RH - é a umidade relativa em %

V - velocidade do vento em m/s

Para o cálculo do índice de Temperatura Efetiva em função do vento (TEv), dividiu-se o índice em subíndices, sendo: TEv₁, obtido pela combinação de temperatura máxima e umidade relativa mínima; TEv₂, calculado com base no valor máximo da temperatura do ar e o valor máxima de umidade relativa do ar, ambos representativos das tardes; TEv₃, obtido através de valores de temperatura mínima e umidade relativa mínima; TEv₄, calculado pela combinação de temperatura mínima e umidade relativa máxima. Os índices TEv₃ e TEv₄ são índices representativos das manhãs. Por fim obteve-se o índice TEv₅, baseado nos valores médios de temperatura do ar e umidade relativa do ar.

3.3 Regressão Linear Multivariada

A análise de Regressão Múltipla é uma metodologia estatística para previsão de valores de uma ou mais variáveis de resposta (dependentes) através de um conjunto de variáveis explicativas (independentes). Esta metodologia pode ser utilizada para a avaliação dos efeitos das variáveis explicativas como previsoras das variáveis de resposta (HAIR et al. 2005).

Neste modelo estatístico a variável dependente (número de internações hospitalares) é uma variável discreta inteira e as variáveis independentes são variáveis meteorológicas (temperatura máxima e mínima, umidade máxima e mínima, velocidade do vento e os índices de conforto térmico humano (CTH)).

O impacto das variáveis meteorológicas na saúde da população pode apresentar uma defasagem em relação à exposição dos indivíduos aos agentes climáticos (COELHO, 2007). Portanto, os atendimentos observados em um dia específico podem tanto estar relacionados ao sistema meteorológico atuante no dia, como em sistemas observados em dias anteriores. Logo, foi necessário determinar uma estrutura de "lag" (defasagem em dias).

Foram utilizados "lags" variando de um a sete dias, pois as doenças do trato respiratório geralmente apresentam uma defasagem em relação a essa exposição do ser humano às mudanças de tempo.

Os dados foram tratados em uma planilha eletrônica, usando um intervalo de confiança de 95% e um nível de significância de 5%, ou seja, apenas as variáveis com o valor-p menor que 5% foram utilizadas para a elaboração da equação.

O formato geral da equação de Regressão Linear Múltipla proposta por Wilks (2006) é:

$$Y = a + b_1 X_1 + b_2 X_2 + \dots + b_k X_k$$
 Eq. 2

Onde:

Y – Variável Dependente

a – Representa o intercepto (constante)

b_k – Coeficiente associado às variáveis independentes

X_k – Variáveis Independentes

3.4 Análises de Componentes Principais

Aplicou-se o método da análise de componentes principais (ACP). A ACP transforma uma série de variáveis originais em uma série menor de combinações lineares que explicam a maior parte da variância da série principal dos dados.

Segundo Wilks (2006) a técnica chamada de Análise de Componentes Principais (ACP) tem como objetivo principal explicar a estrutura de variância e covariância de um vetor aleatório, composto de p-variáveis aleatório, através da construção de combinações lineares das variáveis originais.

A técnica se fundamenta na relação da qual uma matriz quadrática simétrica pode ser decomposta em outras matrizes que preservam a variabilidade dos dados.

Essas componentes principais são extraídas de maneira que a primeira componente principal, explica a maior parte da variação dos dados. Desse modo, a primeira componente principal é a combinação linear das variáveis observadas. A segunda componente principal é a combinação linear das variáveis observadas e essas não estão correlacionadas com a primeira combinação linear, explicando a variação total máxima restante que possa ter passado despercebido pela primeira combinação.

A transformação dos dados originais em um novo conjunto faz uso da matriz correlação ou da matriz covariância dos dados originais.

Neste estudo foi utilizada a matriz correlação, onde é mostrado o grau de associação entre duas variáveis aleatórias X e Y, expressadas pelo coeficiente de correlação, que é uma medida definida a partir da covariância entre duas variáveis aleatórias:

$$Cor_{(X,Y)} = \frac{Cov_{(X,Y)}}{\sqrt{Var_{(X)}Var_{(Y)}}}$$
Eq.3

Onde:

 $Cov_{(X,Y)}$ é a covariância de X e Y, definida por:

$$Cov_{(x,Y)} = \frac{\sum_{i=1}^{n} (X_i - \overline{X}).(Y_i - \overline{Y})}{n-1}$$
 Eq.4

 $Var_{(X)}$ é a variância de X e $Var_{(Y)}$ é a variância de Y, definidas por:

$$Var_{(X)} = \frac{\sum_{i=1}^{n} (X_i - \overline{X})^2}{n-1}$$
 Eq.5

$$Var_{(Y)} = \frac{\sum_{i=1}^{n} (Y_i - \overline{Y})^2}{n-1}$$
 Eq.6

Sobre a matriz correlação são extraídos os autovalores e os autovetores. De forma simplificada, pode-se dizer que os autovalores representam o percentual de explicação de cada equação e os autovetores representam os pesos individuais de cada amostra dentro da equação.

Dessa maneira, qualquer matriz quadrática simétrica pode ser decomposta nas matrizes com autovalores e autovetores com valores reais, sendo que, a matriz de autovetores <u>V</u> expressa à mudança de base para um novo sistema de referência, os quais são definidos pelos autovetores normalizados da matriz M (correlação).

Os autovetores normalizados (pesos individuais da variação em cada posição) associados a cada autovalor (peso coletivo de todas as posições) são definidos de padrão de oscilação principal, que tem como função identificar áreas de maior importância na explicação parcial de cada autovalor.

Cada autovalor tem um percentual de explicação individual que é definido pela relação do valor da raiz da solução *i* comparados ao somatório das *p* possíveis soluções das equações que descrevem a matriz correlação.

Para cada autovalor λ_i da matriz M, equivale a um conjunto p de autovetores

Porção
$$_{\rm i} = \frac{\lambda_i}{\displaystyle\sum_{a=1}^p \lambda_a}$$
 % de contribuição de λ_i na variação total Eq.7

Assim, pode-se escolher o percentual relativo da variação total no ajuste desejado.

Através da combinação desses autovetores <u>V</u> decorrentes da matriz de correlação e os dados originais Y, produzem novas variáveis que são definidas como escores das componentes principais (CP's). Esses escores representam valores numéricos encontrados através do cálculo da multiplicação de uma componente principal com a matriz original dos dados, que para o caso em estudo, foram utilizados apenas os dois primeiros escores.

3.5 Redes Neurais

RNs são modelos matemáticos úteis na execução de determinadas tarefas de aprendizagem, tais como, associação e reconhecimento de padrões, aproximação de funções, controle e filtragem (HAYKIN, 2001).

A aplicação de uma RN é feita em duas fases, são elas: aprendizagem e ativação. A fase de aprendizagem, também conhecida como treinamento, consiste no processo de adaptação dos pesos sinápticos das conexões e dos níveis de limiar (viéses) dos neurônios em resposta às entradas. A ativação consiste no processo de receber uma entrada e produzir uma saída de acordo com a arquitetura final da rede.

3.5.1 Rede Perceptron de Múltiplas Camadas (RPMC)

A RPMC consiste de uma camada de entrada formada por padrões que serão apresentados a rede durante a fase de treinamento (também chamados de conjunto de unidades sensoriais ou nós de fonte), uma ou mais camadas escondidas de nós computacionais e uma camada de saída de nós computacionais. O sinal de entrada se propaga para frente através da rede, camada por camada. Segundo Haykin (2001), a RPMC tem três características distintas:

- 1) o modelo de cada neurônio da rede inclui uma função de ativação nãolinear, sendo que esta função de ativação deve ser diferenciável em todos os pontos,
- 2) a rede contém uma ou mais camadas de neurônios ocultos. Estes neurônios ocultos capacitam a rede a aprender tarefas complexas extraindo progressivamente as características mais significativas dos padrões de entrada,
- 3) a rede exibe um alto grau de conectividade, determinada por suas sinapses.

Tratando-se de redes neurais, dois pontos chaves no processo de aprendizagem precisam ser definidos: (i) qual o paradigma de aprendizado (supervisionado ou não-supervisionado); e, (ii) após definir-se o paradigma, definese a regra de aprendizado, que é a regra segundo a qual os pesos sinápticos dos neurônios são ajustados passo a passo até o sistema atingir o estado estável.

Neste trabalho, a RPMC foram implementadas com aprendizado por errocorreção (também conhecido como algoritmo de retropropagação do erro ou Regra Delta de Widrow) e paradigma de aprendizado supervisionado. As redes são totalmente conectadas, apresentam uma camada de entrada, apenas uma camada escondida e a camada de saída. Na Fig. 2 ilustra-se as redes implementadas neste trabalho.

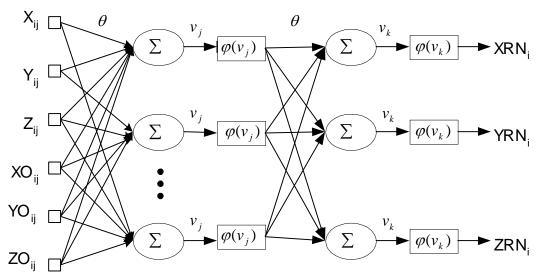


Figura 2: Ilustração da Rede Neural aplicada nesse trabalho

A seguir resume-se o algoritmo de retropropagação, segundo Haykin (2001), utilizado no treinamento da RPMC.

- 1 Iniciação: assumindo nenhuma informação prévia disponível, os pesos sinápticos e limiares são iniciados com valores que seguem uma distribuição uniforme.
- 2 Apresentação dos exemplos de treinamento: apresenta-se uma época de exemplos de treinamento à rede. Para cada exemplo do conjunto de treinamento executa-se os passo 3 e 4 apresentados a seguir.
- 3 Cálculo para Frente (Propagação): sendo um exemplo do conjunto de treinamento representado por (x(n),d(n)), com o vetor de entrada x(n) aplicado a camada de entrada de nós sensoriais e o vetor resposta desejada d(n) apresentado à camada de saída de nós computacionais, calcula-se os campos locais induzidos e os sinais funcionais camada por camada da rede. O campo local induzido $v_j^{(l)}(n)$ para o neurônio j na camada-l é

$$v_j^{(l)}(n) = \sum_{i=0}^{m_0} \theta_{ji}^{(l)}(n) y_i^{(l-1)}(n)$$
 Eq. 8

onde $y_i^{(l-1)}(n)$ é o sinal de saída do neurônio i na camada interior i, na iteração i, e i e o peso sináptico do neurônio i da camada i, que é alimentado pelo neurônio i da camada i. Para i e i e o viés aplicado ao neurônio i na camada i. O sinal de saída do neurônio i na camada i e o viés aplicado ao neurônio i na camada i e

$$y_{i}^{l} = \varphi_{i}(v_{i}(n))$$
 Eq. 9

Se o neurônio j está na primeira camada oculta (i.e., l=1), faz-se $y_j^{(o)}(n) = x_j(n)$, $x_j(n)$ é o j-ésimo elemento do vetor de entrada j. Se o neurônio j está na camada de saída (i.e., l=L onde j edenominado a profundidade da rede), se faz j j está na camada de saída (i.e., j está na camada (i.e., j está na camada de saída (i.e., j está na camada (i

Calcula-se o sinal de erro

$$e_{i}(n) = d_{i}(n) - o_{i}(n)$$
 Eq.10

onde $d_{j}(n)$ é o j -ésimo elemento do vetor resposta desejada d(n) .

 4 - Cálculo para Trás (Retropropagação): Calcula-se os gradientes locais da rede definidos por

$$\delta_i^{(l)}(n) = e_i^{(L)}(n)\varphi_i^{(l)}(v_i^{(L)}(n))$$
 Eq. 11

para o neurônio \dot{J} da camada de saída L, ou por

$$\delta_{j}^{(L)}(n) = \varphi_{j}^{(l)}(v_{j}^{(l)}(n)) \sum_{k} \delta_{k}^{(l+1)}(n) \theta_{kj}^{(l+1)}(n)$$
 Eq. 12

para um neurônio j da camada oculta l, onde o apóstrofo em $\varphi_j(.)$ representa a diferenciação em relação ao argumento. Assim, ajusta-se os pesos sinápticos da rede na camada l de acordo com a regra delta generalizada:

$$\theta_{ii}^{(l)}(n+1) = \theta_{ii}^{(l)}(n) + \alpha[\theta_{ii}^{(l)}(n-1)] + \eta \delta_{i}^{(l)}(n) y_{i}^{(l-1)}(n)$$
 Eq.13

onde η é a taxa de aprendizagem e α é a constante de momento.

5 - Iteração: repete-se os itens 3 e 4 , apresentando a rede novos exemplos de treinamento até que o critério de parada seja satisfeito.

Observação: a ordem de apresentação dos exemplos de treinamento deve ser aleatória, de época para época. Os parâmetros de momento e a taxa de aprendizagem são ajustados com o número de iterações.

Resultados e Discussões

A análise da Regressão Linear Múltipla (RLM) entre as variáveis meteorológicas (temperatura máxima e mínima, umidade máxima e mínima), os índices de conforto humano (TEv₁, TEv₂, TEv₃, TEv₄ e TEv₅), os 'lags' destas variáveis (com defasagem em até sete dias) e o índice de internações causadas por Influenza/Pneumonia (IP), AVAI (Afecção das Vias Aéreas Inferiores) e AVAS (Afecção das Vias Aéreas Superiores) obtidas através de uma planilha eletrônica, são apresentados a seguir:

4.1 Modelo de Regressão Linear Múltipla (MRLM)

O modelo obtido através da técnica de Regressão Linear Múltipla para um nível de significância de 95% para todos os meses, durante todo o período estudado é apresentado abaixo:

$$Y = 2,55TEv_1 + 3TEv_2 + 3,17TEv_3 + 2,55TEv_4 - 11,27TEv_5 - 0,19lag2_TEv_3 + 0,16lag2_TEv_4 + 4,11$$
 Eq.14

Aplicou-se a técnica conhecida como validação cruzada para avaliar o modelo obtido. Esta técnica consiste em dividir o conjunto de dados em dois subconjuntos, sendo que o primeiro subconjunto foi utilizado para correlação e o segundo subconjunto para verificar os resultados de internação hospitalar estimados pelo modelo estatístico. A seguir, na tab. 1, apresenta-se o resultado da validação cruzada.

Tabela 1 - Número de internações por Influenza/Pneumonia observadas (IP) e número de internações por Influenza/Pneumonia estimadas (IP').

IP	IP'
0	2,32
5	2,68
0	1,96
2	2,81
3	3,20
5	2,91
4	3,09
2	2,98
2	2,85
0	3,67

De acordo com os resultados apresentados na tab. 1, o modelo não foi capaz de quantificar as internações hospitalares por Influenza/Pneumonia (IP) e nem identificar picos de internação.

Nessa análise conjunta dos fatores associados à IP, verificou-se que das variáveis meteorológicas aplicadas, os Índices de Conforto Humano de Temperatura Efetiva em função do Vento TEv₁, TEv₂, TEv₃, TEv₄ e TEv₅ permaneceram no modelo como variáveis que impactam sendo que, TEv₅ teve um maior impacto (valor em módulo), ou seja, os valores médios de temperatura do ar e umidade relativa do ar não foram significativos no modelo. No que diz respeito aos índices de Temperatura Efetiva com as defasagens (lags), apenas os índices lag2_TEv₃ e lag2_TEv₄ impactaram na análise do modelo, porém lag2_TEv₃ teve um impacto negativo sobre o mesmo. Todavia, todos os valores dos coeficientes são bastante baixos.

O teste abaixo foi reproduzido no intuito de se calcular a correlação entre as variáveis meteorológicas e os casos de internações causadas por Afecções das Vias Aéreas Superiores (AVAS), que se refere a problemas do tipo faringite, laringite, sinusite, rinite e amigdalite na seção 4.2 e internações causadas por Afecções das Vias Aéreas Inferiores (AVIS), que são diagnosticadas como bronquite, traqueíte, asma, bronquite asmática, entre outros problemas, na seção 4.3, separadamente, com o objetivo de se obter um resultado melhor.

4.2 Modelo de Regressão Linear Múltipla (MRLM) para AVAS

Através dos dados obtidos pela Regressão Linear Múltipla, criou-se outro modelo para o mesmo nível de significância de 95%. O cálculo foi realizado a partir da seguinte equação matemática:

$$Y = -0.92TEv_1 - 1.16TEv_2 - 1.32TEv_3 - 0.83TEv_4 + 4.24TEv_5 - 0.04lag1_TEv_3 - 0.09lag3_TEv_3 + 0.05lag1_TEv_4 - 0.05lag2_TEv_4 + 0.10lag3_TEv_4 + 0.49$$
 Eq. 15

Após a determinação do modelo, a técnica de validação cruzada, já explicada anteriormente, foi adotada a fim de testar o primeiro subconjunto de dados correlacionados e o segundo subconjunto a fim de verificar os resultados estimados pelo modelo gerado (tab.2).

Tabela 2 - Número de internação por Afecção das Vias Aéreas Superiores observadas (AVAS) e número de internação por Afecção das Vias Aéreas Superiores (AVAS')

AVAS	AVAS'
0	0,27
0	0,69
2	0,82
0	0,68
0	0,82
0	0,57
0	0,60
1	0,62
0	0,42
0	0,46

Analisando os dados exemplificados através da tab. 2, mesmo estando com valores aproximados, pode-se notar que essa correlação entre os dados observados e os estimados não representam positivamente em relação ao grau de satisfação do modelo apresentado. Verificou-se que as variáveis meteorológicas impactantes nessa análise foram os índices de conforto TEv1, TEv2, TEv3, TEv4 e TEv5, porém

apenas TEv5 teve um impacto positivo, ou seja, nesse caso, as temperaturas médias do ar e as umidades médias do ar foram as únicas comum grau de importância significativa no modelo. Os índices com defasagens lag1_TEv3, lag3_TEv3, lag1_TEv4, lag2_TEv4 e lag3_TEv4 entraram no cálculo desse modelo, porém apenas as lag1_TEv4 e lag3_TEv4 impactaram de maneira positiva nessa solução, mostrando que as defasagens tanto de um dia como em três dias do índice biometeorológico de temperatura efetiva em função do vento (TEv4) foram as variáveis que tiveram maior importância significativa para o cálculo desse modelo.

4.3 Modelo de Regressão Linear Múltipla (MRLM) para AVAI

Com base nos dados obtidos através da Regressão Linear Múltipla, foi apresentada outra equação matemática expressa por:

$$Y = 0.09lag3_TEv_3 + 0.01lag2_TEv_4 - 0.08lag3_TEv_4 + 0.28$$
 Eq. 16

O processo utilizado para quantificar essas internações hospitalares também se deu a partir da técnica de validação cruzada, conforme apresentado abaixo (tab.3).

Tabela 3: Número de internação por Afecção das Vias Aéreas Inferiores observadas (AVIS) e número de internação por Afecção das Vias Aéreas Inferiores estimadas (AVIS')

AVAI	AVAI'
0	0,59
0	0,34
1	0,29
1	0,49
0	0,47
1	0,27
0	0,44
0	0,62
0	0,34
0	0,35

Observando os dados exemplificados através da tab.3, pode-se notar que mesmo com os valores estimados baixo, ainda não se chegou a uma correlação representativa positiva. As variáveis utilizadas para o cálculo foram os índices de conforto com defasagens de dois a três dias, ou seja, lag3_TEv3, lag2_TEv4, lag3_TEv4 impactaram sobre a solução, sendo que, a temperatura mínima do ar e a umidade máxima do ar com defasagem em três dias (lag3_TEv4), teve um impacto negativo nesse modelo.

De forma geral, os modelos obtidos nesse estudo através da Regressão Linear Múltipla (RLM) não foram satisfatórios para a previsão de internações hospitalares tanto para IP quanto para AVAS e AVIS. No entanto, de acordo com a literatura, essas doenças não dependem apenas das condições meteorológicas, mas também podem estar relacionadas com fatores sociais, culturais e genéticos. Todavia, a causa dos altos erros do modelo é o conjunto de dados pouco abrangente e as falhas nos dados. Pode ter havido internação não registrada, pessoas que não procuram atendimento médico, o hospital não é o único a atender a pacientes acometidos por AVAS, AVIS e IP, embora seja o maior. Pode haver dados registrados incorretamente, como erros de digitação.

4.4 Análises de Componentes Principais

A análise de componente principal é uma técnica multivariada utilizada quando se tem um grande número de variáveis relacionadas. Essas variáveis são transformadas em um conjunto menor de variáveis correlacionadas. Essa técnica permite reescrever os dados da matriz original em um novo conjunto de componentes principais que são linearmente independentes e conseguem explicar a maior parte da variação dos dados originais (WILKS, 2006)

4.4.1 Análise de Componentes Principais para o mês de Junho para IP

Na Fig. 3 foram calculados os autovalores das componentes principais para todos os meses de junho dos anos de 2002 a 2009 para Influenza/Pneumonia. Os autovalores mostram o quanto da variância de cada fator retido foi explicado. No eixo horizontal é apresentado o número das análises de componentes principais

calculadas. O eixo vertical representa o percentual de significância de cada componente principal calculada. Entre todas as CP's calculadas, notaram-se valores maiores na primeira componente (20,25%) e na segunda (14,93%) contabilizando um total de 35,18% da explicação das variáveis.

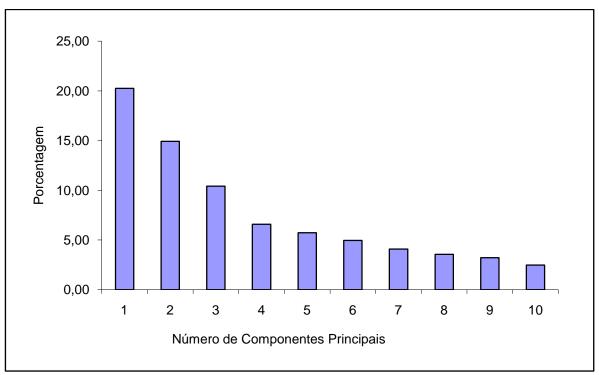


Figura 3: Significância em percentual para cada análise de componente principal para junho

Analisou-se a primeira componente principal das variáveis meteorológicas e IP para todos os meses de junho no período de 2002 a 2009, Fig.4. O eixo vertical representa os valores dos pesos de cada variável. O eixo horizontal representa as 68 variáveis envolvidas na análise das componentes principais. No apêndice A são apresentados os nomes das variáveis.

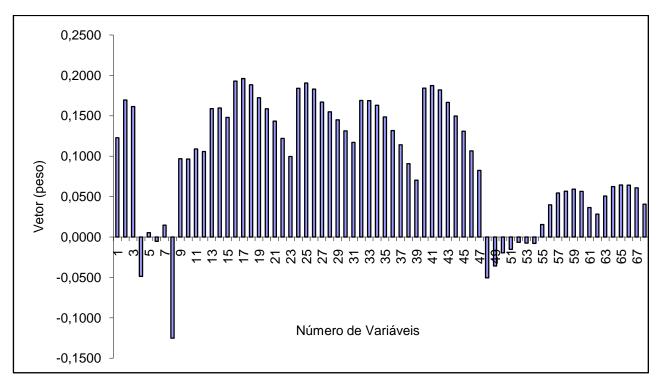


Figura 4: Análise das variáveis da primeira componente principal para junho

Foi possível identificar as variáveis com maiores valores, apresentados na tab.4.

Tabela 4: Variáveis mais significativas da primeira análise de componentes principais para o mês de junho

Número da Variável	Nome da Variável	Vetor (peso)
17	Lag2_Tmin	0,1962
16	Lag1_Tmin	0,1930
25	Lag2_Tmed	0,1907
18	Lag3_Tmin	0,1885
41	Lag2_TEv4	0,1875
40	Lag1_TEv4	0,1842
24	Lag1_Tmed	0,1841
26	Lag3_Tmed	0,1831
42	Lag3_TEv4	0,1820
19	Lag4_Tmin	0,1724

Pode-se observar que, de todas as variáveis analisadas, os dados de defasagem de um a quatro dias (lags) de temperatura mínima, temperatura média e o lag do índice biometeorológicos TEv4 (combinação de temperatura mínima e umidade máxima) são os elementos mais importantes da primeira componente principal.

Na Fig. 5 analisaram-se as variáveis meteorológicas e IP para a segunda componente principal, podendo identificar quais foram os valores com maior significância (tab.5)

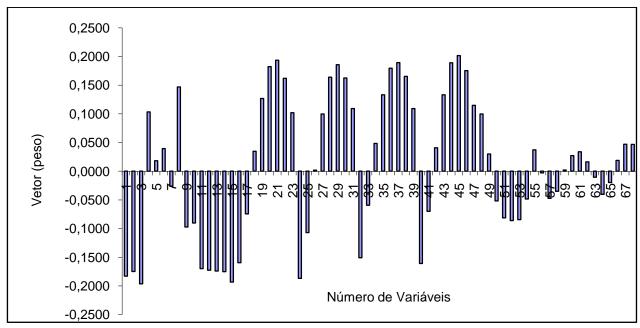


Figura 5: Análise das variáveis da segunda componente principal para junho

Tabela 5: Variáveis mais significativas da segunda análise de componentes principais para o mês de junho

Nome da Variável	Vetor (peso)
Lag6_TEv4	0,2017
Tmed	-0,1964
Lag6_Tmin	0,1937
TEv5	-0,1934
Lag6_TEv3	0,1895
Lag5_TEv4	0,1892
Lag1_Tmed	-0,1868
Lag6_Tmed	0,1858
Tmax	-0,1830
Lag5_Tmin	0,1826
	Lag6_TEv4 Tmed Lag6_Tmin TEv5 Lag6_TEv3 Lag5_TEv4 Lag1_Tmed Lag6_Tmed Tmax

Nota-se que para a análise da segunda componente principal, os elementos com pesos maiores foram defasagens de um, cinco e seis dias. Além disso, diferente da tab.4, encontrou-se valores negativos mais representativos em algumas ocasiões, ou seja, para valores negativos, indica-se relação inversa entre as variáveis.

4.4.2 Análise de Componentes Principais para o mês de Julho

A Fig.6 representa os cálculos dos autovalores das componentes principais para todos os meses de julho dos anos de 2002 a 2009. No eixo horizontal estão descritos os números de análises de componentes principais calculadas e no eixo vertical mostra os valores em percentual de cada análise realizada. Através do gráfico, pode-se notar que as duas primeiras componentes principais somam aproximadamente 36% da variância de cada elemento.

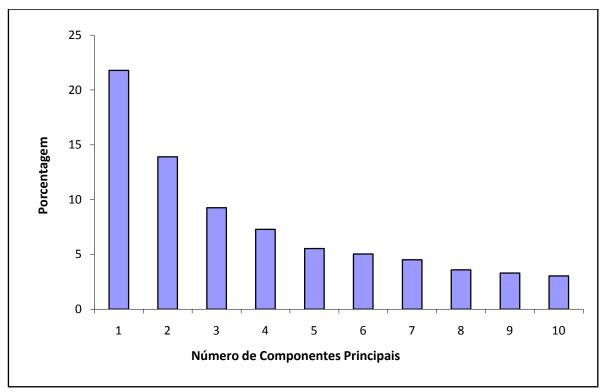


Figura 6: Significância em percentual para cada análise de componente principal para julho

As variáveis meteorológicas e IP foram analisadas para a primeira componente principal de todos os meses de julho durante o período de oito anos (2002 a 2009), conforme mostra a Fig. 7, indicando quais foram os elementos que melhor representaram essa componente conforme mostra a tab.6.

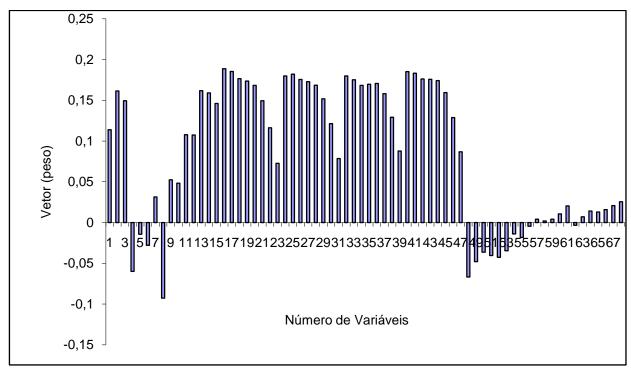


Figura 7: Análise das variáveis da primeira componente principal para julho

Tabela 6: Variáveis mais significativas da primeira análise de componentes principais para o mês de julho

Número das Variáveis	Nomes das Variáveis	Vetor (peso)
16	Lag1_Tmin	0,1886
17	Lag2_Tmin	0,1853
40	Lag1_TEv4	0,1851
41	Lag2_TEv4	0,1832
25	Lag2_Tmed	0,1820
32	Lag1_TEv3	0,1798
24	Lag1_Tmed	0,1798
18	Lag3_Tmin	0,1765
42	Lag3_TEv4	0,1761
43	Lag4_TEv3	0,1757

Conforme a tab.6, os elementos de maior significância são os dias com defasagens de um a três dias de temperatura mínima, defasagem de um e dois dias de temperatura média e defasagens de um a quatro dias em relação aos índices biometeorológicos TEv3 (combinação da temperatura mínima e umidade mínima) e TEv4 (combinação da temperatura mínima com a umidade máxima). No geral, esses índices representam as manhãs. Pode-se perceber que essa primeira análise da

componente principal para os meses de julho apresentam o mesmo comportamento da análise dos meses de junho, pois esses meses apresentam condições de tempo semelhantes.

Na análise feita para a segunda componente principal é possível verificar uma variação maior dos dados indicando mais resultados negativos do que positivos, ou seja, apresentam uma relação inversa entre as variáveis, impactando negativamente no grau de significância dos dados.

Segue abaixo a tab.7 com os valores de maior significância.

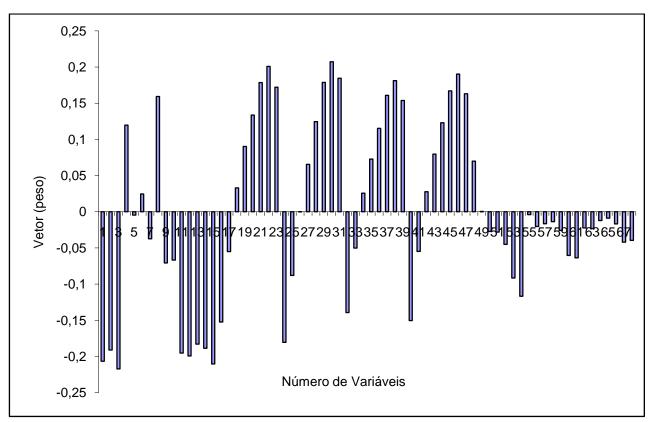


Figura 8: Análise das variáveis da segunda componente principal para julho

Tabela 7: Variáveis mais significativas da segunda análise de componentes

principais para o mês de julho

Número das Variáveis	Nome das Variáveis	Vetor (peso)
30	Lag7_Tmed	-0,2172
22	Lag7_Tmin	-0,2104
3	Umed	0,2073
46	Lag7_TEv4	-0,2066
15	TEv5	0,2008
13	TEv3	-0,1993
14	TEv4	-0,1953
2	Tmin	-0,1912
1	Tmax	0,1901
11	TEv1	-0,1887

Nota-se que os valores da segunda componente principal para os meses de julho tiveram contribuição de maneira negativa maior do que positiva.

O maior peso foi o da variável de defasagem em sete dias da temperatura media, porém de forma negativa. Com relação a temperatura máxima e mínina, a correlação não se mostra tão significativa. A umidade relativa média foi bastante significativa, além disso, o índice biometeorológico TEv5 tem um peso impactante positivamente nessa análise, visto que esse índice relaciona a temperatura média e a umidade relativa média.

4.4.3 Análise de Componentes Principais para o mês de Agosto para IP

Na Fig. 9 foram calculados os autovalores das componentes principais para todos os meses de agosto dos anos de 2002 a 2009. No eixo horizontal é apresentado o número das análises de componentes principais que foram calculadas. O eixo vertical representa o peso de cada componente em percentual.

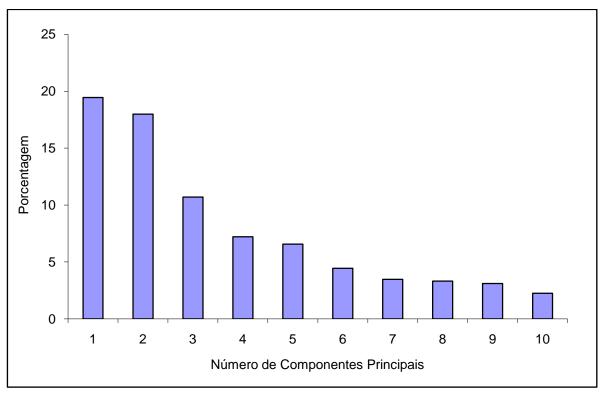


Figura 9: Significância em percentual para cada análise de componente principal para agosto

A Fig. 10 representa os cálculos das variáveis meteorológicas e IP da primeira componente principal de todos os meses de agosto durante o período de 2002 a 2009, indicando quais foram os elementos que melhor representaram essa componente conforme mostra a tab.8.

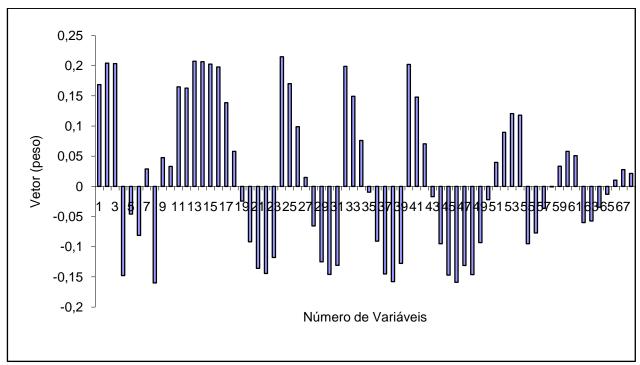


Figura 10: Análise das variáveis da primeira componente principal para agosto

Tabela 8:	Variáveis	mais	significativas	da	segunda	análise	de	componentes
principais į	oara o mês	de ago	sto					

Número das Variáveis	Nome das Variáveis	Vetor (peso)	
24	Lag1_Tmed	0,2147	
13	TEv3	0,2072	
14	TEv4	0,2065	
2	Tmin	0,2040	
3	Tmed	0,2031	
15	TEv5	0,2026	
40	Lag1_TEv4	0,2020	
32	Lag1_TEv3	0,1988	
16	Lag1_Tmin	0,1976	
25	Lag2_Tmed 0,1702		

Observou-se que as defasagens (lags) de um a dois dias tiveram peso maior na análise da primeira componente, indicando significância positiva em todos os valores. Esses resultados também se assemelham aos meses de junho e julho devido às condições do tempo.

Na fig. 11 foram apresentados os vetores pesos para a segunda análise de componente principal para os meses de agosto do período estudado (2002 a 2009).

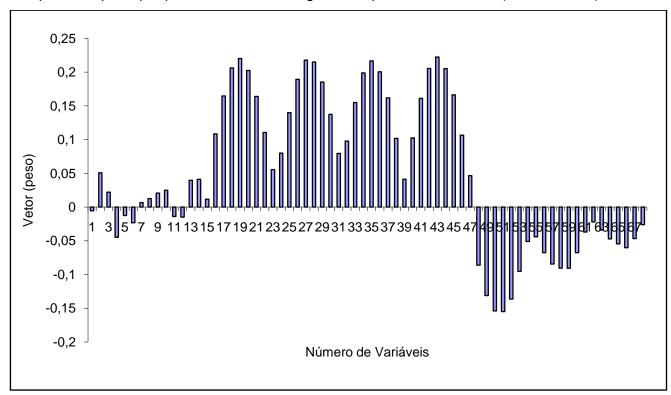


Figura 11: Análise das variáveis da segunda componente principal para agosto

Tabela 9: Variáveis mais significativas da segunda análise de componentes principais para o mês de agosto

Número das Variáveis	Nome das Variáveis	Vetor (peso)	
43	Lag4_TEv4	0,2222	
19	Lag4_Tmin	0,2200	
27	Lag4_Tmed	0,2176	
35	Lag4_TEv3	0,2164	
28	Lag5_Tmed	0,2178	
42	Lag3_TEv4	0,2054	
44	Lag5_TEv4	0,2051	
20	Lag5_Tmin	0,2022	
36	Lag5_TEv3	0,2003	
34	34 Lag3_TEv3		

Conforme a tab.9 os valores encontrados para segunda componente principal foram todos positivamente significantes, porém as únicas variáveis de peso maior fora os lags (defasagem de três a cinco dias) tanto para temperatura mínima, temperatura média e também para os índices biometeorológicos TEv3 e TEv4.

No geral, as análises de componentes principais para todos os meses de junho, julho e agosto estudados mostraram que, os lags de temperatura mínima e média e os lags dos índices biometeorológicos relacionados com o vento TEv3 e TEv4 são os índices com maior significância estatística em relação a IP. Isto sugere que, as mudanças nas condições do tempo mesmo sentidas no primeiro dia, têm seu efeito nas internações após três dias ou quatro dias.

Essa condição é esperada clinicamente, pois, segundo Coelho (2007), ao respirar ar frio, as células ciliadas ficam paralisadas e, parte das defesas do organismo que são realizadas por elas, deixa de ocorrer. Dessa maneira, os seios nasais ficam mais propensos as infecções respiratórias. Porém, as doenças infecciosas levam certo tempo para se agravarem fazendo com que as pessoas demorem a recorrerem de ajuda hospitalar.

4.5 Rede Neural Perceptron de Múltiplas Camadas

A metodologia baseada na RPMC, conforme explicado na metodologia tem duas fases, a saber: treinamento e ativação (previsão).

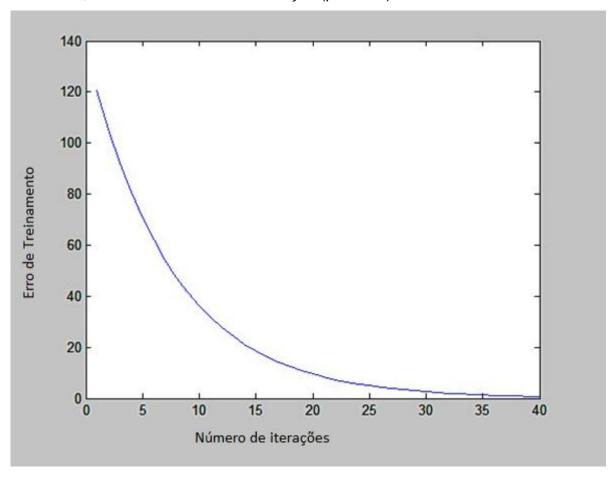


Figura 12: Erro de treinamento da RPMC.

Na fig. 12 é mostrado o erro de treinamento da rede. O eixo vertical representa o erro de treinamento e o eixo horizontal representa o número de interações realizadas.

Observa-se que o erro de treinamento diminui drasticamente durante as 40 primeiras interações, o que indica que a rede foi efetiva no aprendizado do conjunto de treinamento utilizado. Entretanto, os resultados da fase de ativação mostram (não apresentados, por discordarem completamente da realidade) que a rede foi incapaz de prever o número de internações hospitalares (IP's). A causa deste resultado pode ser: overfitting, ou seja, a rede se especializou no conjunto de treinamento e foi incapaz de estimar dados não contidos no conjunto de treinamento, poucos padrões de treinamento, taxa de aprendizagem incorreta e número de neurônios e camadas

insuficientes. Portanto, os resultados indicam que a metodologia deve ser mais bem investigada. Em trabalhos futuros pretende-se utilizar redes auto configuráveis, redes nas quais os parâmetros empíricos sejam determinados pela própria rede neural.

Conclusão

Os resultados gerados pelos Modelos de Regressão Linear Múltipla (MRLM) mostraram que a correlação foi baixa entre as variáveis meteorológicas (temperatura máxima, mínima, e média do ar e umidade máxima, mínima e média do ar e velocidade do vento), os índices de conforto térmico humano (CTH) representados pela Temperatura Efetiva em função do Vento (TEv₁, TEv₂, TEv₃, TEv₄ e TEv₅) e as internações hospitalares de crianças de zero a cinco anos causadas por doenças respiratórias, Influenza/Pneumonia (IP), Afecção das Vias Aéreas Superiores (AVAS) e Afecção das Vias Aéreas Inferiores (AVAI).

Sabe-se que pessoas com problemas respiratórios sofrem cada vez mais tanto com a poluição atmosférica como com as mudanças bruscas no tempo. Ao calcular tanto as regressões multivariadas como as análises de componentes principais, observou-se uma associação estatisticamente significante entre os lags (defasagem em dias) e o aumento de internações hospitalares por doenças do aparelho respiratório.

Quanto à metodologia baseada em Redes Neurais Artificiais (RNA) apresentada na seção 4.5, verificou-se que a Rede Perceptron de Múltiplas camadas (RPMC) conseguiu "aprender", mas não foi capaz de generalizar (estimar/prever) o número de internações com base no histórico de dados apresentados a rede.

Na continuidade deste estudo, as metodologias devem ser aperfeiçoadas no intuito de se atingir os objetivos propostos. Para tal, devem-se investigar os parâmetros empíricos da RPMC, como taxa de aprendizagem, número de neurônios e número de camadas escondidas e/ou utilizar redes auto reguláveis, ou seja, redes neurais que determinem estes parâmetros empríricos. No tocante à RLM, busca-se abordar uma correlação somente para os dias com maiores picos de internação

hospitalar durante o período estudado, a fim de encontrar uma correlação mais significativa das internações hospitalares com as variáveis meteorológicas abordadas no estudo.

Referências

BOTELHO, C. L.; LOPES, A.; CORREIA, A. C. S.; GONÇALVES, A. M.; CLYSTENES, O. S. S. Environmental factors and hospitalization of under-five children with acute respiratory infection. **Caderno de Saúde Pública**. Rio de Janeiro v. 19, n. 6, 2003.

BRAUN, S. Influências meteorotrópicas nas doenças cardiovasculares na cidade de São Paulo. 2003, 148 p. Dissertação de Mestrado, Instituto de Astronomia, Geofísica e Ciências Atmosféricas de São Paulo.

BRITTO, F; BARLETTA, R; MENDONÇA, M. Regionalização sazonal e mensal da preciptação pluvial máxima no estado do Rio Grande do Sul. **Revista Brasileira de Climatologia**, v. 2, p. 35-51, 2006.

CARDOSO, M. R. A. Micro-clima nos domicílios e doenças sibilantes na cidade de São Paulo. 2007, 103 p.Tese de Livre Docência, FSP-USP.

COELHO, M. S. Uma análise estatística com vistas a previsibilidade de internações por doenças respiratórias em função de condições meteorotrópicas na cidade de São Paulo. 2007,195 p. Tese de Doutorado, Instituto de Astronomia, Geofísica e Ciências Atmosféricas de São Paulo.

EMBRAPA (Empresa Brasileira de Pesquisa Agropecuária) Clima Temperado. Resumos Mensais. Disponível em:

http://www.cpact.embrapa.br/agromet/online/Resumos_Mensais.htm. Acesso em: 19 de nov. de 2013.

FANGER, P.O. **Thermal comfort**. New York: McGraw-Hill Book Company, 1970. p. 244.

GONÇALVES F.L.T.; BRAUN S; DIAS, P.L.D.S; SHARVSY R. Influences of the weather and air pollutants on cardiovascular disease in the metropolitan area os Sao Paulo. **Environmental research**. Vol 104, pp 2750281. 2007.

HAIR, J.F.; ANDERSON, R.E.; TATHAM, R.L; BLACK,W. Análise multivariada de dados. Porto Alegre, Bookman, 2005

- HAYKIN, S. **Redes neurais: princípios e práticas**. Porto Alegre: Bookman, 2001. 900 p
- JAMASON, P. F., KALKSTEIN, L. S., GERGEN, P. J. A synoptic evaluation of asthma hospital admissions in New York City. **American Journal of Respiratory Care Medicine and Critical**, v. 156, p. 1781-1788, 1997.
- KASSOMENOS P. A.; GRYPARIS A.; KATSOUUYANNI K. On the association between daily mortality and air mass types in Athens, Greece during winter and summer. **International journal of biometeorology**, v. 51, p. 3150322, 2007.
- KOEPPEN, W. Climatologia: **Con un estudio de los climas de la tierra**. Fondo de Cultura Economica, 1948. 3 ed, p. 478.
- LIN, C.A. Efeitos da poluição atmosférica sobre a morbidade respiratória aguda na população infantil de São Paulo. São Paulo SP. 1999, 115 p. Tese de doutorado. Faculdade de Medicina, Universidade de São Paulo.
- MAIA, J. A. **Uma análise do conforto térmico e suas relações meteorotrópicas na cidade de São Paulo**. 2002, 134 p. Dissertação de Mestrado, Instituto de Astronomia, Geofísica e Ciências Atmosféricas de São Paulo.
- MELARA, E. A espacialização da violência criminal na cidade de Santa Maria, RS. Confins. **Revista Franco-Brasilera de Geografia**, n. 14, 2012.
- MINISTÉRIO DA SAÚDE. Anuário Estatístico de Saúde do Brasil 2001. Disponível em: http://portal.saude.gov.br/saude/aplicacoes/anuario2001. Acesso em: 7 de dez. de 2013.
- MINISTÉRIO DA SAÚDE. Anuário Estatístico de Saúde do Brasil 2008. Disponível em: http://portal.saude.gov.br/saude/aplicacoes/anuario2008>. Acesso em: 18 de out. de 2013.
- MOURA, M.; JUNGER, W. L.; MENDONÇA, G. A. S.; DE LEON, A. P. Qualidade do ar e transtornos respiratórios agudos em crianças. **Revista de Saúde Pública** v. 42, n. 3, p. 503-511, 2008.
- NEDEL, A. S. Condições Meteorológicas Favoráveis à Ocorrência de Doenças Respiratórias em Crianças da Cidade de São Paulo. 2008, 195 p. Tese de Doutorado, Instituto de Astronomia, Geofísica e Ciências Atmosféricas de São Paulo.
- RUSTICUCCI, M; HARRIS, M; ACOSTA E. Relación entre las causas de internación en un hospital general y las condiciones meteorológicas durante el año 1995. **Actas do**... 2001, pp 4590460.
- SALDIVA, P.H.N Association between air Pollution and mortality due to respiratory diseases in children in São Paulo, Brazil: A preliminary report. **Environmental Research**. vol. 65, n.2, pp. 2180225.1994.

SUPING, Z.; GUANGLIN, M.; YANWEN, W.; Ji, L. Study of the relationships between weather conditions and the marathon race, and of meteorotropic effects on distance runners. **International Journal of Biometeorology**, v. 36, p. 6308, 1992.

TROMP, S.W. Biometeorology: The impact of the weather and climate on humans and their environment (animals and plants). **London: Heiden**, 1980.

WILKS, D. S. **Statistical methods in the atmospheric scienses**. 2ed. Elsevier. San Diego, 2006, 630p.

APÊNDICE A

Neste apêndice, são mostrados os nomes das variáveis utilizadas nas componentes principais.

Número da Variável	Nome da Variável	Significado da Variável	
1	Tmax	Temperatura Máxima	
2	Tmin	Temperatura Mínima	
3	Tmed	Temperatura Média	
4	UR_max_	Umidade Relativa Máxima	
5	UR_min_	Umidade Relativa Mínima	
6	UR_med	Umidade Relativa Média	
7	Precipita	Precipitação	
8	Pressaomed	Pressão Média	
9	Vtomed_	Vento médio	
10	v_0_75		
11	TEv1	Temperatura Efetiva em Função do Vento (Tmax e URmin)	
12	TEv2	Temperatura Efetiva em Função do Vento (Tmax e URmax)	
13	TEv3	Temperatura Efetiva em Função do Vento (Tmin e URmin)	
14	TEv4	Temperatura Efetiva em Função do Vento (Tmin e URmax)	
15	TEv5	Temperatura Efetiva em Função do Vento (Tmed e URmed)	
16	Lag1_Tmin	Defasem de um dia na Temperatura Mínima	
17	Lag2_Tmin	Defasagem de dois dias na Temperatura Mínima	
18	Lag3_Tmin	Defasagem de três dias na Temperatura Mínima	
19	Lag4_Tmin	Defasagem de quatro dias na Temperatura Mínima	
20	Lag5_Tmin	Defasagem de cinco dias n Temperatura Mínima	
21	Lag6_Tmin	Defasagem de seis dias na Temperatura Mínima	
22	Lag7_Tmin	Defasagem de sete dias na Temperatura Mínima	
23	Lag8_Tmin	Defasagem de oito dias na Temperatura Mínima	

24	Lag1_Tmed	Defasagem de um dia na Temperatura Média
25	Lag2_Tmed	Defasagem de dois dias na Temperatura Média
26	Lag3_Tmed	Defasagem de três dias na Temperatura Média
27	Lag4_Tmed	Defasagem de quatro dias na Temperatura Média
28	Lag5_Tmed	Defasagem de cinco dias na Temperatura Média
29	Lag6_Tmed	Defasagem de seis dias na Temperatura Média
30	Lag7_Tmed	Defasagem de sete dias na Temperatura Média
31	Lag8_Tmed	Defasagem de oito dias na Temperatura Média
32	Lag1_TEv3	Defasagem de um dia na Temperatura Efetiva em Função do Vento (Tmin e URmin)
33	Lag2_TEv3	Defasagem de dois dias na Temperatura Efetiva em Função do Vento (Tmin e URmin)
34	Lag3_TEv3	Defasagem de três dias na Temperatura Efetiva em Função do Vento (Tmin e URmin)
35	Lag4_TEv3	Defasagem de quatro dias na Temperatura Efetiva em Função do Vento (Tmin e URmin)
36	Lag5_TEv3	Defasagem de cinco dias na Temperatura Efetiva em Função do Vento (Tmin e URmin)
37	Lag6_TEv3	Defasagem de seis dias na Temperatura Efetiva em Função do Vento (Tmin e URmin)
38	Lag7_TEv3	Defasagem de sete dias na Temperatura Efetiva em Função do Vento (Tmin e URmin)
39	Lag8_TEv3	Defasagem de oito dias na Temperatura em Função do Vento (Tmin e URmin)

Lag1_TEv4	Defasagem de um dia na Temperatura Efetiva em Função do Vento (Tmin e URmax)
Lag2_TEv4	Defasagem de dois dias na Temperatura Efetiva em Função do Vento (Tmin e URmax)
Lag3_TEv4	Defasagem de três dias na Temperatura Efetiva em Função do Vento (Tmin e URmax)
Lag4_TEv4	Defasagem de quatro dias na Temperatura Efetiva em Função do Vento (Tmin e URmax)
Lag5_TEv4	Defasagem de cinco dias na Temperatura Efetiva em Função do Vento (Tmin e URmax)
Lag6_TEv4	Defasagem de seis dias na Temperatura Efetiva em Função do Vento (Tmin e URmax)
Lag7_TEv4	Defasagem de sete dias na Temperatura Efetiva em Função do Vento (Tmin e URmax)
Lag8_TEv4	Defasagem de oito dias na Temperatura Efetiva em Função do Vento (Tmin e Urmax)
Lag1_URmax	Defasagem de um dia na Umidade Relativa Máxima
Lag2_URmax	Defasagem de dois dias na Umidade Relativa Máxima
Lag3_URmax	Defasagem de três dias na Umidade Relativa Máxima
Lag4_URmax	Defasagem de quatro dias na Umidade Relativa Máxima
Lag5_URmax	Defasagem de cinco dias na Umidade Relativa Máxima
Lag6_URmax	Defasagem de seis dias na Umidade Relativa Máxima
Lag7_URmax	Defasagem de sete dias na Umidade Relativa Máxima
	Lag2_TEv4 Lag3_TEv4 Lag4_TEv4 Lag5_TEv4 Lag7_TEv4 Lag1_URmax Lag2_URmax Lag2_URmax Lag3_URmax Lag4_URmax Lag4_URmax Lag5_URmax Lag5_URmax Lag5_URmax Lag6_URmax

55	Lag1_URmed	Defasagem de um dia na Umidade Relativa Média
56	Lag2_URmed	Defasagem de dois dias na Umidade Relativa Média
57	Lag3_URmed	Defasagem de três dias na Umidade Relativa Média
58	Lag4_URmed	Defasagem de quatro dias na Umidade Relativa Média
59	Lag5_URmed	Defasagem de cinco dias na Umidade Relativa Média
60	Lag6_URmed	Defasagem de seis dias na Umidade Relativa Média
61	Lag7_URmed	Defasagem de sete dias na Umidade Relativa Média
62	Lag1_URmin	Defasagem de um dia na Umidade Relativa Mínima
63	Lag2_URmin	Defasagem de dois dias na Umidade Relativa Mínima
64	Lag3_URmin	Defasagem de três dias na Umidade Relativa Mínima
65	Lag4_URmin	Defasagem de quatro dias na Umidade Relativa Mínima
66	Lag5_URmin	Defasagem de cinco dias na Umidade Relativa Mínima
67	Lag6_URmin	Defasagem de seis dias na Umidade Relativa Mínima
68	Lag7_URmin	Defasagem de sete dias na Umidade Relativa Mínima