

Uma Comparação de Previsão de Receita para a Indústria Automobilística Usando Neurais e Regressão Linear

A Revenue Forecast Comparison for the Automobile Industry Using Neural and Linear Regression
Una comparación de pronósticos de ingresos para la industria automotriz mediante regresión neuronal y lineal

Recebido
Received
Recibido
Fevereiro, 2025
February, 2025
Febrero, 2025

Aceito
Accepted
Aceptado
Março, 2025
March, 2025
Marzo, 2025

Publicado
Published
Publicado
Abril, 2024
April, 2024
Abril, 2024

<https://git.fateczl.edu.br>

e_ISSN
2965-3339

DOI
10.29327/2384439.3.3-4

São Paulo
v. 3 | n. 3
v. 3 | i. 3

e33308

Abril-Junho
April-June
Abril-Junio
2025



Roberto Giro Moori¹
roberto.g.moori@gmail.com

André Ng²
a_ng@bol.com.br

Roberto Ramos de Morais³
1125656@mackenzie.br

Plácido de Jesus da Silva Leitão Junior⁴
placido.leitao@mackenzie.br

1 – Universidade Presbiteriana Mackenzie

Resumo: Redes neurais artificiais (RNAs) são ferramentas utilizadas na construção de modelos de sistemas complexos. Suas principais características incluem: aprendizado e redução do volume de dados para a modelagem. Este estudo exploratório comparou o desempenho dos modelos baseados em regressão linear múltipla e das redes neurais para prever as receitas da indústria automobilística. Foram utilizados dados secundários, referentes ao período de 1980 a 2001, coletados da ANFAVEA (2002). Os resultados mostraram que o erro médio do modelo de previsão baseado em redes neurais foi menor do que o modelo baseado em regressão linear múltipla.

Palavras-chave: Indústria automobilística; receita; redes neurais; regressão linear.

Abstract: Artificial neural networks (ANNs) are tools used in the construction of complex system models. Their main characteristics include learning and the reduction of the volume of data for modelling. This exploratory study compared the performance of the models based on multiple linear regression and the neural networks to forecast the revenues of the automotive industry. We used secondary data, regarding the period from 1980 to 2001, collected from ANFAVEA (2002). The results showed that the average error of the forecast model based on neural networks was smaller than the model based on multiple linear regression.

Keywords: Automobile industry; revenue; neural networks; linear regression.

Resumen: Las redes neuronales artificiales (RNA) son herramientas que se utilizan para construir modelos de sistemas complejos. Sus principales características incluyen: aprender y reducir el volumen de datos para modelar. Este estudio exploratorio comparó el rendimiento de modelos basados en regresión lineal múltiple y redes neuronales para predecir los ingresos en la industria del automóvil. Se utilizaron datos secundarios, referidos al período de 1980 a 2001, recogidos de ANFAVEA (2002). Los resultados mostraron que el error promedio del modelo de predicción

basado en redes neuronales fue menor que el del modelo basado en regresión lineal múltiple.

Palabras clave: *Industria automotriz; ganancia; redes neuronales; regresión lineal.*

1. INTRODUÇÃO

Nos últimos anos, o Brasil tem sido apontado como uma das economias emergentes, com capacidade de gerar novas perspectivas para o desenvolvimento socioeconômico da América Latina. Para a indústria automobilística já instalada no País, segundo projeções até o ano de 2030, serão investidos R\$ 95 bilhões (Moliterno, 2024). Com o aumento da competitividade, as montadoras automobilísticas estão adotando técnicas de produção cada vez mais modernas e enxutas. Muitos dos processos produtivos adotados no Brasil serão exportados para outras fábricas em todo mundo (Silva, 2000, B7). Naturalmente, nas estratégias adotadas pela indústria, é importante considerar a competitividade. Entretanto argumenta Ohmae (1998, 68) que, ao se adotar uma estratégia, ela não se deve ser colocada em primeiro lugar. Antes disso, vem a atenção total às necessidades e a adição de valor dos produtos entregues aos clientes, bem como organizar o sistema de negócios que os planejem, fabriquem e os vendam. O planejamento das atividades empresariais é uma atividade comum a qualquer tipo de empresa, independente de tamanho ou de ramo a que se dedique. É imperativo que as empresas tenham abordagens eficazes para prever, e que seja parte integrante do planejamento dos negócios. Constantemente, todas as áreas estão envolvidas com planejamento, de maneira formal ou informal. Todos os dias os administradores determinam no presente quais cursos serão tomados no futuro, sem saber o que acontecerão. Há um sem-número de decisões que compõem o próprio planejamento ou são dele derivadas. Eles encomendam estoques sem saber como serão as vendas, adquirem novos equipamentos apesar das incertezas sobre a demanda de produtos e fazem investimentos sem saber quais serão os lucros. Os administradores estão sempre tentando fazer melhores estimativas do que irá ocorrer no futuro em face da incerteza. Fazer boas estimativas é o principal propósito das previsões, que se tornam as entradas para as estratégias de negócios como os planejamentos de novas instalações, planejamento da produção, programação da força de trabalho e outras.

Neste contexto, de competitividade e da necessidade de adicionar valor aos produtos adquiridos pelos clientes, este trabalho teve por objetivo comparar o desempenho entre a aplicação de um modelo de previsão de faturamento baseado em uma rede neural e o modelo de previsão baseado em regressão linear múltipla. Na análise da previsão do faturamento da indústria automobilística nacional foram consideradas as vendas internas, a exportação de veículos e os investimentos realizados no período de 1980 a 2001.

Ao fazer a comparação de desempenhos dos modelos de previsão baseados em redes neurais e em regressão linear múltipla para tratar do conhecimento inexato, imprecisão da informação ou a aleatoriedade das variáveis, envolvida no faturamento da indústria automobilística, está-se contribuindo no desenvolvimento de alternativas nas formulações de previsão de vendas e por conseguinte, no sequenciamento da produção, no dimensionamento da mão-de-obra, nas compras e em outras atividades da gestão da cadeia de suprimentos. Por fim, ao aparecerem resultados firmemente calcados em conceitos objetivos e bem fundamentados, de sorte que as condições de aplicabilidade, vantagens e

as limitações das novas técnicas se tornem claras, certamente essa técnica passará a ser aceita pela comunidade e a incorporar ao acervo de conhecimento a serviço da ciência e da tecnologia, gerando novos negócios, novas empresas e por conseguinte, novos postos de trabalhos, que é o propósito final desta pesquisa.

2. REFERENCIAL TEÓRICO

2.1 REGRESSÃO LINEAR MÚLTIPLA

A regressão linear múltipla é um processo poderoso e flexível para a análise de relações associativas entre uma variável métrica dependente e uma ou mais variáveis independentes. Pode ser utilizada para: (a) determinar se as variáveis independentes explicam uma variação significativa na variável dependente, isto é, se existe uma relação; (b) determinar quanto da variação na variável dependente pode ser explicado pelas variáveis independentes, ou seja, a intensidade da relação; (c) determinar a estrutura ou a forma da relação, a equação matemática que relaciona as variáveis independentes e dependentes; (d) prever os valores da variável dependente e; (e) controlar outras variáveis independentes quando da avaliação das contribuições de uma variável ou conjunto de variáveis específicas. A forma geral do modelo de regressão múltipla é: $Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_3 X_3 + \dots + \beta_k X_k + e$, que é estimado pela seguinte equação: $\hat{Y} = a + b_1 X_1 + b_2 X_2 + b_3 X_3 + \dots + b_k X_k$.

O coeficiente “a” representa o intercepto, e os “b’s” são os coeficientes de regressão parcial. O critério de mínimos quadrados estima os parâmetros de forma a minimizar o erro total (SQ_{res}). Este processo também maximiza a correlação entre os valores efetivos e Y e os valores preditivos \hat{Y} .

As estatísticas associadas à regressão múltipla são as seguintes:

- **R^2 Ajustado:** R^2 ou coeficiente de determinação múltipla, é ajustado para o número de variáveis independentes e para o tamanho da amostra para levar em conta a diminuição de retorno. Após as primeiras variáveis, as variáveis independentes adicionais não dão grande contribuição.
- **Coeficiente de determinação múltipla:** A intensidade de associação em regressão múltipla é medida pelo quadrado do coeficiente de correlação múltipla, R^2 , que é chamado também de coeficiente de determinação múltipla.
- **Teste F:** O teste F é usado para testar a hipótese nula, de que o coeficiente de determinação múltipla na população, R^2_{pop} , é zero. Isto equivale a testar a hipótese nula $H_0: \beta_1 = \beta_2 = \beta_3 \dots = \beta_k = 0$. A estatística de teste tem distribuição F com k e $(n - k - 1)$ graus de liberdade.
- **Teste F Parcial:** Pode-se testar a significância de um coeficiente de regressão parcial, β_i de X_i com auxílio de uma estatística F incremental. A estatística F incremental se baseia no incremento da soma explicada de quadrados resultante da adição da variável independente X_i à equação de

regressão após terem sido incluídas todas as outras variáveis independentes.

- **Teste t:** Testa se a relação entre as variáveis, dependente e independente, são significativas, ou seja, testa indiretamente o coeficiente de correlação da população. Este teste é equivalente ao teste F parcial.
- **Coefficiente de regressão parcial:** O coeficiente de regressão parcial, b_1 , denota a variação no valor preditivo \hat{Y} , por unidade de variação em X_1 , quando as outras variáveis independentes, X_2 a X_k , são mantidas constantes. Pode ser interpretado também como o coeficiente de regressão bivariada, “b”, para a regressão de Y sobre os resíduos de X_1 , quando o efeito de X_2 a X_k , foi removida de X_1 .

Um dos problemas que ocorrem no uso de regressão linear múltipla em série de tempo são:

- a) multicolinearidade. Neste caso, precisa-se determinar se as variáveis escolhidas, não são funções lineares exata, uma da outra. Isto pode produzir um alto R^2 e conduzir a conclusões errôneas sobre o modelo;
- b) heterocedasticidade. A construção do modelo preditivo parte do pressuposto que a variância dos dados e do termo errático, “e”, mantém-se constante ao longo do tempo (homocedasticidade). Hoje, com o desenvolvimento de robustas técnicas de análise estatística, sabe-se que tal pressuposto é facilmente violado e;
- c) tamanho da série. Séries muito longas, faz com que algumas das variáveis percam suas informações intrínsecas. Séries curtas podem ser tendenciosas. Uma forma muito utilizada para validar a regressão linear múltipla, é o teste “d” de Durbin-Watson (GUAJARATI, 2000, 422).

Embora as variáveis independentes possam explicar a variação na variável dependente, isto não implica necessariamente uma causalidade. O emprego das expressões variável dependente ou de critério, variável independente, previsora ou preditiva na análise de regressão decorre da relação matemática entre as variáveis. Esses termos não implicam que a variável de critério seja dependente das variáveis independentes em um sentido causal. O objetivo da análise de regressão é a natureza e o grau de associação entre variáveis, não implica nem supõe qualquer causalidade. A premissa básica da regressão múltipla é que o modelo inclua todas as variáveis importantes e relevantes. Se uma variável importante for omitida, a capacidade de previsão do modelo fica reduzida. Além disso, se a variável omitida estiver correlacionada com uma variável incluída, o coeficiente estimado desta última vai refletir ambas as variáveis. Outras limitações consideradas para a aplicação da regressão múltipla são:

- a. o modelo baseia-se em dados coletados que representam certas condições ambientais. Se essas condições mudam, o modelo não mais refletirá a situação corrente e pode conduzir a julgamentos errôneos;

- b. a capacidade de previsão do modelo, refletida por R^2 , pode tornar-se significativamente reduzida se a previsão for baseada em valores das variáveis independentes que sejam extremos em comparação aos valores dessas mesmas variáveis utilizadas para estimar os parâmetros do modelo e;
- c. o modelo é cercado pela metodologia associada com a coleta dos dados, incluindo-se o tamanho da amostra e as mensurações empregadas.

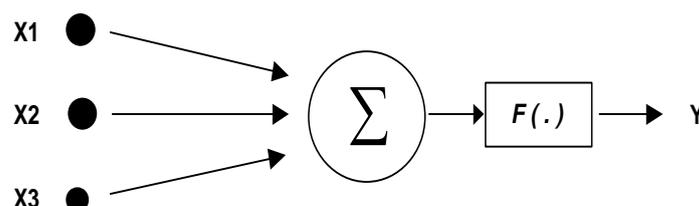
2.2 REDES NEURAIS

Redes neurais são sistemas computacionais, de implementação em hardware ou software, que imitam as habilidades do sistema nervoso biológico, usando um grande número de simples neurônios artificiais interconectados (Loesch; Sari, 1996). Os neurônios artificiais são simples emulações dos neurônios biológicos, estes recebem informação de sensores ou de outros neurônios artificiais. As redes neurais funcionam através de seus neurônios artificiais, que processam seus dados usando paralelismo lógico (para todos os neurônios da mesma camada) combinado com operações seriais (quando a informação de uma camada é transferida para neurônios de outra camada). Existem três características principais que descrevem uma rede neural, e que contribuem para sua habilidade funcional: estrutura, dinâmica e aprendizado do sistema neural.

Estrutura: Uma unidade computacional de processamento de informação ou neurônio é fundamental para a operação de uma rede neural. Haykin (2001, 36) identifica três elementos básicos em um modelo neural (Figura 1):

- a) um conjunto de sinapses ou elos de conexão, cada uma caracterizada por um peso ou força própria. Um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} , onde k refere-se ao neurônio em questão e j refere-se ao terminal de entrada da sinapse à qual o peso se refere;
- b) um somador para somar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio e ;
- c) uma função de ativação para restringir a amplitude da saída de um neurônio. A função de ativação é também referida como função restritiva já que restringe (limita) o intervalo permissível de amplitude do sinal de saída a um valor finito.

Figura 1: Modelo de um neurônio artificial



Fonte: os autores.

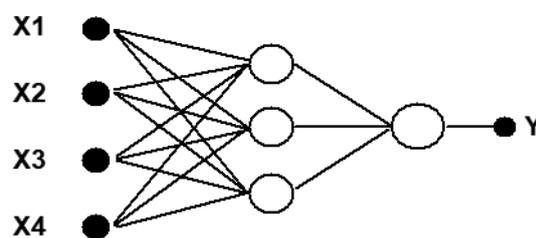
O modelo neural de Haykin (2001) inclui também um viés (bias) aplicado externamente. O bias tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo, respectivamente.

A saída de unidades computacional de processamento é definida por uma função de ativação. Os principais tipos de função de ativação, têm-se: Linear, sigmóide ou tangente hiperbólica e base radial.

A maneira pela qual os neurônios estão estruturados está intimamente ligada com o algoritmo de aprendizagem usado para treinar a rede. Haykin (2001) identifica três classes de arquiteturas de rede fundamentalmente diferentes:

- a) redes alimentadas adiante com camada única. Os neurônios organizados em camadas, na forma mais simples de uma rede de camadas, têm-se uma camada de entrada de nós de fonte que se projeta sobre uma camada de saída de neurônios (nós computacionais);
- b) redes alimentadas diretamente com múltiplas camadas. A segunda classe de uma rede neural alimentada adiante se distingue pela presença de uma ou mais camadas ocultas, cujos nós computacionais são chamados correspondentemente de neurônios ocultos ou unidades ocultas. A Figura 2 representa uma rede neural com múltiplas camadas, totalmente conectada. A função dos neurônios ocultos é intervir entre a camada externa e a saída da rede de maneira útil. Adicionando-se uma ou mais camadas ocultas, a rede torna-se capaz de extrair estatísticas de ordem elevada. A habilidade de os neurônios ocultos extraírem estatísticas de ordem elevada é particularmente valiosa quando o tamanho da camada de entrada é grande;
- c) redes recorrentes. Uma rede neural recorrente se distingue de uma rede neural alimentada adiante por ter pelo menos um laço de realimentação. Uma rede recorrente pode consistir, por exemplo, de uma única camada de neurônios com cada neurônio alimentando seu sinal de saída de volta para as entradas de todos os outros neurônios.

Figura 2: Modelo de Rede Neural



Fonte: os autores.

Dinâmica: O funcionamento das unidades de processamento se dá da seguinte forma: cada uma recebe um ou mais sinais de entrada, provenientes de unidades de unidades a ela conectadas. Esses sinais são multiplicados pelos pesos de suas respectivas conexões e somados, produzindo o chamado nível de atividade. O valor resultante será usado como entrada da função de ativação, que o processará e gerará a saída do neurônio. Essa saída, então, será repassada às

unidades de processamento seguintes (CARTACHO et al, 2002).

Aprendizagem: As redes neurais possuem a capacidade de aprender por exemplos e fazer interpolações e extrapolações do que aprenderam. Um conjunto de procedimentos bem definidos para adaptar os parâmetros de uma rede neural para que ela possa aprender uma determinada função é chamado de algoritmo de aprendizagem. Não há um único algoritmo de aprendizagem. O que se tem é um conjunto de ferramentas representadas por diversos algoritmos, cada qual com suas vantagens e desvantagens (BRAGA, et al, 2000). Estes algoritmos basicamente diferem pela maneira como o ajuste dos pesos é feito. Diversos métodos para treinamentos de redes foram desenvolvidos, podendo ser agrupados em dois paradigmas principais:

- a) aprendizado supervisionado. Este método de aprendizado é o mais comum no treinamento das redes neurais, tanto de neurônios com pesos como de neurônios sem pesos. É chamado de aprendizado supervisionado porque a entrada e saída desejadas para a rede são fornecidas por um supervisor (professor) externo. O objetivo é ajustar os parâmetros da rede, de forma a encontrar uma ligação entre os pares de entrada e saída fornecidos;
- b) aprendizado não supervisionado. Como o próprio nome sugere, não há um professor ou supervisor para acompanhar o processo de aprendizado. Para estes algoritmos, somente os padrões de entrada estão disponíveis para a rede, ao contrário do aprendizado supervisionado, cujo conjunto de treinamento possui pares de entrada e saída. A partir do momento em que a rede estabelece uma harmonia com as regularidades estatísticas da entrada de dados, desenvolve-se nela uma habilidade de formar representações internas para codificar características de entrada e criar classes ou grupos automaticamente. Este tipo de aprendizado só se torna possível quando existe redundância nos dados de entrada. Sem redundância seria impossível encontrar quaisquer padrões ou características dos dados de entrada.

A estrutura do sistema de aprendizado não supervisionado pode adquirir uma variedade de formas diferentes. Ela pode, por exemplo, consistir em uma camada de entrada, uma cama de saída, conexões *feedforward* da entrada para a saída e conexões laterais entre os neurônios da camada de saída. Um outro exemplo é uma rede *feedforward* com múltiplas camadas, em que a livre organização procede na base de camada por camada. Nestes dois exemplos, o processo de aprendizagem consiste em modificar repetidamente o peso sináptico de todas as conexões do sistema em resposta às entradas.

Para resolver uma certa tarefa, existe uma estrutura de rede e seu respectivo algoritmo de treinamento. Sem muitos detalhes, as diferentes estruturas de rede, as funções de ativação e os algoritmos de treinamento mais usados, são:

- a) *Multilayer Perceptron* (MLP), é a rede mais popular hoje em dia. A sua função de ativação é a *logistic function*, que pode ser treinada por algoritmos como *Conjugate Gradient Descent*, *Quasi-Newton*, *Levenberg-Marquardt*, *Back Propagation* or *Delta-bar-Delta*.

- b) *Radial Basis Function* (RBF), é composta de uma camada de entrada, uma camada oculta de unidades radiais e uma camada de saída de unidades lineares. Tipicamente a camada oculta de unidades radiais tem uma função de ativação exponencial e a camada de saída uma função de ativação linear. As redes RBF podem ser treinadas por algoritmos como a *center-assignment*, *deviation assignment* e *linear optimization*.
- c) *Linear Network*, tem somente duas camadas, uma camada de entrada e uma de saída. A função de ativação pode ser interpretada como sendo um peso vindo de uma unidade cuja saída é sempre 1 (NASCIMENTO JR e YONEYAMA, 2000, 116). Ela pode ser treinada usando a técnica *Pseudo-Inverse*, isto é, a última camada é otimizada para se obter uma função linear. Ela também pode ser treinada utilizando a análise dos componentes principais.
- d) Kohonen, é composta de uma camada de entrada e uma camada de saída de unidades radiais. É usada principalmente na classificação de clusters. A função de ativação é a raiz quadrada. Ela pode ser treinada usando um algoritmo de aprendizagem não supervisionado e; (e) outros, pertencentes do grupo Bayesian Networks como o *Probabilistic Neural Network* (PNN) e *Generalized Regression Neural* (GRNN).

3 METODOLOGIA

3.1 DADOS

Para comparar o desempenho de previsão de faturamento da indústria automobilística, com base nos modelos em regressão linear múltipla e redes neurais, foram utilizados dados secundários coletados junto à ANFAVEA (2002) referente ao período de 1980 a 2001.

Para se ter uma visão mais ampla da evolução das informações coletadas e facilitar as entradas (*inputs*) nos modelos de previsões, decidiu-se transformá-los em números-índices. Para que os índices pudessem ser consistentes, foram observadas três propriedades (Simonsen; Cysne, 1995):

- a) i) ou 1;
- b) o índice do período t com base no período i é o inverso do índice do período i com base no período t (propriedade da reversão do tempo) e;
- c) o índice do período t com base no período i é igual ao produto do índice do período t com base no período j pelo índice do período j com base no período i (propriedade da cadeia).

Assim exposto, um índice referente ao período t com base no período i, foi dado pela seguinte fórmula:

$$I_i^t = \frac{V_t}{V_i} \times 100,$$

onde V_i é o valor inicial (valor de base de comparação) e V_t é o valor no tempo t.

Os dados coletados bem como os seus respectivos índices, são mostrados na

Tabela 1.

Tabela 1: Dados coletados e seus respectivos índices (BASE = 1980)

ANO	FATURAMENTO		VENDAS INTERNAS		EXPORTAÇÃO		INVESTIMENTO	
	(10 ⁶) US\$	Índice	Unidades	Índice	Unidades	Índice	(10 ⁶) US\$	Índice
1980	11.999	100	793.028	100	115.482	100	489	100
1981	9.193	76,61	447.608	56,44	157.228	136,15	645	131,90
1982	10.542	87,86	556.229	70,14	120.305	104,18	530	108,38
1983	9.977	83,15	608.499	76,73	132.804	115,00	373	76,28
1984	9.822	81,86	532.235	67,11	151.962	131,59	293	59,92
1985	12.477	103,98	602.069	75,92	160.626	139,09	478	97,75
1986	11.961	99,68	672.384	84,79	132.241	114,51	526	107,57
1987	12.856	107,14	410.260	51,73	279.530	242,06	580	118,61
1988	14.515	120,97	556.744	70,20	226.360	196,01	572	116,97
1989	13.459	112,17	566.582	71,45	164.885	142,78	602	123,11
1990	10.036	83,64	532.791	67,18	120.377	104,24	790	161,55
1991	10.316	85,97	597.892	75,39	127.153	110,11	880	179,96
1992	12.812	106,78	596.964	75,28	243.126	210,53	908	185,69
1993	14.843	123,70	903.828	113,97	249.607	216,14	886	181,19
1994	17.760	148,01	1.127.673	142,20	274.815	237,97	1.195	244,38
1995	17.863	148,87	1.407.073	177,43	189.721	164,29	1.694	346,42
1996	19.297	160,82	1.405.545	177,24	211.565	183,20	2.359	482,41
1997	21.159	176,34	1.569.727	197,94	305.647	264,67	2.092	427,81
1998	20.292	169,11	1.211.885	152,82	291.788	252,67	2.335	477,51
1999	16.858	140,50	1.011.847	127,59	204.024	176,67	1.791	366,26
2000	18.359	153,00	1.176.774	148,39	283.449	245,45	1.651	337,63
2001	21.667	180,57	1.295.119	163,31	318.637	275,92	1.150	235,17

Fonte: ANFAVEA (2002)

3.2 REGRESSÃO LINEAR MULTIPLA

Para a construção do modelo de previsão, foi considerado o faturamento como variável dependente. Como variáveis independentes foram considerados as vendas internas, exportação e investimentos. Para efetuar os cálculos foi

utilizado o pacote de estatística, SPSS®, cujos resultados obtidos são mostrados na Tabela 2.

Tabela 2: Construção do modelo de previsão para o faturamento

	Coeficientes não padronizados (B)	Erro Padrão	Coeficientes padronizados (Beta)	t	Nível de Significância
(Constante)	28,603	6,307		4,535	0,000
Vendas Internas	0,443	0,083	0,604	5,317	0,000
Exportação	0,232	0,040	0,411	5,882	0,000
Investimentos	0,01809	0,028	0,072	0,645	0,527

R = 0,972 $F_{(3,18)} = 102,91$

R² = 0,9449 p < 0,00000

R² ajustado = 0,9357 Erro padrão estimado = 8,5235

Da Tabela 2, observa-se que o modelo estimado para a previsão do faturamento para a indústria automobilística será dado por:

$$\text{Faturamento} = 28,603 + 0,443 \times \text{Vendas internas} + 0,232 \times \text{Exportação} + 0,01809 \times \text{Investimentos}$$

Os erros padrão são estimados em 6,307; 0,083; 0,040 e 0,028 e o valor da estatística “t” são: 4,535; 5,317; 5,882 e 0,645, com 18 graus de liberdade (n – 4), para a constante, vendas internas, exportação e investimentos, respectivamente.

O valor crítico de “t”, retirado da Tabela de distribuição “t” com 18 graus de liberdade e nível de significância, $\alpha = 5\%$, para um teste bicaudal é de 2,1009. Como o valor calculado de “t” é maior do que o valor crítico, exceto para a variável “investimento”, rejeita-se a hipótese nula. Logo, existe uma relação linear significativa entre o faturamento e as variáveis representadas pelas vendas internas e exportação. Não é representativo para a variável “investimento”, que pode ser excluída da função preditiva do “faturamento”.

Uma outra medida para examinar a significância da relação linear entre Faturamento e as variáveis independentes, representadas pelas vendas internas, exportação e investimento, é o teste dado pela estatística “F”.

Observa-se, na Tabela 2, que a estatística “ $F_{(3,18)}$ ” é igual a 102,906. O valor crítico de F, com 3 e 18 graus de liberdade (n – 4), retirado da Tabela de distribuição “F” com nível de significância, $\alpha = 5\%$, é igual a 3,16, isto é, bem menor que o valor calculado de 102,906. Portanto, a relação do faturamento com as variáveis independentes é

significativa. Entretanto, observou-se pelo teste “t”, que a variável “investimento” não era significativa em nível de significância de 5%. Uma outra inferência relacionada à intensidade da relação é dada pelo coeficiente de correlação, dado por R^2 . Observa-se que o R^2 é igual a 0,9449, o que significa dos dados tem um bom ajuste à função, pois que o coeficiente R^2 pode variar entre 0 e 1. Entretanto, para evitar conclusões erradas provocadas como por exemplo, pela multicolinearidade entre as variáveis, foi feito o teste de Durbin-Watson, como mostram as Tabelas 3 e 4.

Tabela 3: Erro Quadrático Médio e teste Durbin-Watson (DW)

ANO	Faturamento Real (1)	Faturamento Preditivo (2)	Erro (e _i) (1) – (2)	e _{i-1}	(e _i – e _{i-1})	(e _i – e _{i-1}) ²	Erro Quadrático (e _i) ²
1980	100,00	97,9969	2,0031				4,012
1981	76,61	87,6650	-11,0550	2,0031	-13,0581	170,514	122,213
1982	87,86	85,8812	1,9788	-11,055	13,0338	169,880	3,916
1983	83,15	90,7380	-7,5880	1,9788	-9,5668	91,524	57,578
1984	81,86	90,0338	-8,1738	-7,588	-0,5858	0,343	66,811
1985	103,98	96,3677	7,6123	-8,1738	15,7861	249,201	57,947
1986	99,68	94,7635	4,9165	7,6123	-2,6958	7,267	24,172
1987	107,14	109,9589	-2,8189	4,9165	-7,7354	59,836	7,946
1988	120,97	107,4123	13,5577	-2,8189	16,3766	268,193	183,811
1989	112,17	95,7024	16,4676	13,5577	2,9099	8,468	271,182
1990	83,64	85,5444	-1,9044	16,4676	-18,372	337,530	3,627
1991	85,97	90,8822	-4,9122	-1,9044	-3,0078	9,047	24,130
1992	106,78	114,2832	-7,5032	-4,9122	-2,591	6,713	56,298
1993	123,70	132,6600	-8,9600	-7,5032	-1,4568	2,122	80,282
1994	148,01	151,3944	-3,3844	-8,96	5,5756	31,087	11,454
1995	148,87	151,7303	-2,8603	-3,3844	0,5241	0,275	8,181
1996	160,82	158,5019	2,3181	-2,8603	5,1784	26,816	5,374
1997	176,34	185,6327	-9,2927	2,3181	-11,6108	134,811	86,354
1998	169,11	163,7369	5,3731	-9,2927	14,6658	215,086	28,870
1999	140,50	132,8697	7,6303	5,3731	2,2572	5,095	58,221
2000	153,00	157,5644	-4,5644	7,6303	-12,1947	148,711	20,834
2001	180,57	169,4102	11,1598	-4,5644	15,7242	247,250	124,541
TOTAL	2650,73	2650,73	0	59,443	59,443	2189,769	1307,754
ERRO QUADRÁTICO MÉDIO							59,443

Observa-se, pela Tabela 3, que o Erro Quadrático Médio é igual a 59,443. Por outro lado, aplicando o teste de Durbin Watson (DW) que é dado por: $[(e_i - e_{i-1})^2 / (e_i)^2]$, obtém-se: $(2.189,769 / 1.307,754) = 1,67445$. Os valores críticos de Durbin-Watson (DW), são mostrados na Tabela 4.

Tabela 4: Valores críticos – Durbin-Watson (DW)

			$\alpha = 5\%$	$\alpha = 1\%$
Tamanho da amostra	22	$d_{inferior}$	1,05	0,83
Variáveis independentes	3	$d_{superior}$	1,66	1,40

Assim, observa-se que não há o problema de autocorrelação ou multicolinearidade em níveis de significâncias de 5% e 1%, uma vez que o $DW_{calculado}$ (1,67445) é maior que o $DW_{crítico}$, conforme mostra a Tabela 4.

3.3 REDES NEURAIS

Para a construção e aplicação das redes neurais, utilizou-se o pacote estatístico “Statistica – Neural Networks” da StaSoft Inc. Ao utilizar-se deste software, foi importante ter em mente que a análise de dados em uma rede neural é apresentada como uma “caixa preta”. Não se estava interessado nos parâmetros do modelo como os pesos de ponderação, níveis de significância ou os índices de ajustes do modelo, mas ter o melhor uso da aplicação prática na solução do problema. Na utilização do pacote de redes neurais “Statistica – Neural Networks”, o fornecedor, recomenda os seguintes passos:

- coletar um conjunto de dados relacionados ao problema. A solução de uma rede neural será tão boa quanto aos dados utilizados para o seu treinamento. Se os dados são não representativos ou enviesados, a solução da rede sofrerá, e o modelo gerado não generalizará a população;
- preparar os dados para a análise. Os dados de entrada devem ser preparados, isto é, devem ser removidos os dados fora de escala ou dados anormais, para que seus valores caiam dentro de um limite aceitável;
- analisar as várias topologias de rede como o tipo e o número de camadas. Frequentemente, o melhor tipo e dimensão (tamanho) de uma rede para um problema são desconhecidos. O tamanho para algum tipo de rede, está relacionado com a complexidade do problema a ser solucionado. Quanto mais complexo o problema maior é a demanda para redes maiores, para se obter uma solução apropriada;
- identificar a topologia de rede que melhor generaliza o problema em estudo. O sucesso de solução de uma rede é a boa generalização da população estudada. Quando são tentados diferentes tipos de rede, é conveniente reservar um conjunto de dados para testar a rede para ter certeza que ele não tem aprendido as peculiaridades dos dados de treinamento para a obtenção de uma boa generalização, isto é, um bom ajuste e;
- finalmente administrar a rede identificada para novos dados. Uma vez aceita a solução da rede, esta é estabelecida e a rede salva em arquivo.

Quando novos dados são encontrados, a predição pode ser realizada pela operação e execução da rede para os novos dados.

Assim exposto, os dados coletados e analisados, foram desenvolvidos e comparados por diferentes modelos de redes neurais como pelo número de neurônios e de camadas, algoritmos de treinamento, funções de ativação, número de épocas, tipo de normalização e taxa de aprendizado. Programado para um conjunto de 15 testes, os diferentes resultados obtidos, são mostrados na Tabela 5.

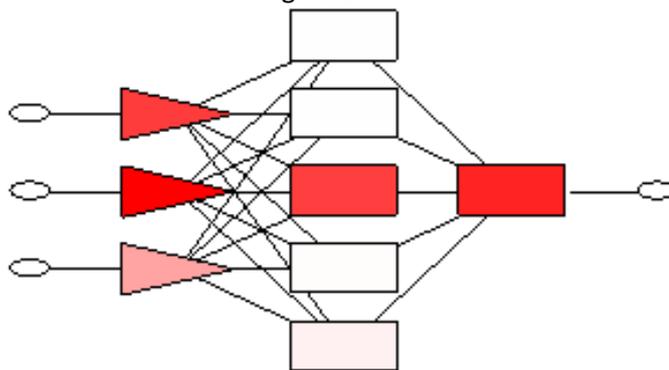
Tabela 5: Diferentes resultados obtidos pela aplicação de diferentes redes neurais

	TIPO	ERRO	ENTRADAS	OCULTAS	DESEMPENHO
01	RBF	25,46267	3	1	0,7751657
02	Linear	13,47182	1	-	0,4101257
03	RBF	9,581519	3	2	0,2916923
04	RBF	8,916316	3	4	0,2714413
05	Linear	7,798546	2	-	0,2374129
06	Linear	7,709793	3	-	0,2347109
07	MLP	7,704029	2	1	0,2345354
08	MLP	7,676821	2	2	0,2335299
09	MLP	7,675677	2	3	0,2336467
10	MLP	7,671636	3	5	0,2335468
11	MLP	7,669094	3	2	0,233468
12	MLP	7,667944	2	6	0,2334308
13	MLP	7,662858	3	2	0,2332696
14	MLP	7,655853	3	6	0,2330483
15 *	MLP	5,635789	3	5	0,1714913

* melhor resultado

Observou-se que a rede que apresentou melhor resultado é Multilayer Perceptron (MLP) com 3 neurônios de entrada, 5 camadas ocultas e 1 camada de saída, com um desempenho de 0,1714913. Na Figura 3, é mostrada a rede neural de melhor desempenho.

Figura 3: Rede MPL: 3: 5: 1



Fonte: os autores.

Identificada a topologia da rede de melhor desempenho foi realizado o seu treinamento. O algoritmo de treinamento mais popular às redes MLP é o algoritmo *back propagation* (Freitas; Souza, 2002). Assim, utilizando-se a rede MLP e o algoritmo de treinamento, *back propagation*, após vários treinamentos, foram obtidos os resultados, conforme são mostrados nas Tabelas 6 e 7. Na Tabela 6 são mostrados o faturamento preditivo e o erro quadrático médio.

Tabela 6: Faturamento Preditivo e Erro Quadrático Médio

ANO	Faturamento Real (1)	Faturamento Preditivo (2)	Erro (e_i) (1) – (2)	Erro Quadrático (e_i) ²
1980	100,000	96,67582	-3,32418	11,050
1981	76,615	76,58133	-0,03338	0,001
1982	87,857	79,30425	-8,55307	73,155
1983	83,149	84,84822	1,699627	2,889
1984	81,857	82,6855	0,828675	0,687
1985	103,984	100,3553	-3,62839	13,165
1986	99,683	97,70482	-1,97848	3,914
1987	107,142	103,6753	-3,46695	12,020
1988	120,968	111,3614	-9,60701	92,295
1989	112,168	99,63841	-12,5293	156,983
1990	83,640	78,77602	-4,86428	23,661
1991	85,974	92,68072	6,706885	44,982
1992	106,776	112,3834	5,607804	31,447
1993	123,702	128,4406	4,738588	22,454
1994	148,012	145,2427	-2,76968	7,671
1995	148,871	146,1774	-2,69333	7,254
1996	160,822	156,605	-4,21674	17,781
1997	176,340	174,1102	-2,22947	4,971
1998	169,114	162,1232	-6,99087	48,872
1999	140,495	126,4433	-14,0517	197,451
2000	153,004	154,0154	1,011019	1,022
2001	180,573	166,3424	-14,2309	202,519
TOTAL	2650,746	2576,17	-74,575	976,245
ERRO QUADRÁTICO MÉDIO				44,375

Observa-se a aplicação da rede neural MLP treinada com o algoritmo *back propagation*, apresentou o erro quadrático médio igual a 44,375. Este dado será importante para a comparação com o erro quadrático médio da regressão linear. A análise de sensibilidade é mostrada na Tabela 7.

Tabela 7: Análise de sensibilidade da rede neural MLP

		Vendas Internas	Exportação	Investimento
Verificação	Rank	1	2	3
	Error	27,49796	18,58897	11,1992
	Ratio	4,127931	2,790533	1,681198
Treinamento	Rank	1	2	3
	Error	27,49796	18,58897	11,1992
	Ratio	4,127931	2,790533	1,681198

Observa-se pela Tabela 7 que a variável “investimento” é a menos significativa na previsão do faturamento, isto é, tem o menor *ratio*. Este fato já foi evidenciado na análise da regressão linear múltipla.

4. ANÁLISE DOS RESULTADOS

Na Tabela 8 são mostrados o Erro Quadrático absoluto e o Erro Quadrático Médio anual para o período de 1980 a 2001, quando se utiliza a previsão de faturamento com base na regressão linear múltipla e redes neurais do tipo *Multilayer Perceptron* (MLP) com 3 neurônios de entrada, 5 camadas ocultas e camada de saída. O algoritmo de treinamento, aplicado ao MLP, utilizado foi o *back propagation*.

Observa-se que para o período estudado, a previsão do faturamento com base em redes neurais apresentou um Erro Quadrático Médio anual de 44,375, o que corresponde a 33,9% menor, ao Erro Quadrático Médio anual quando se utiliza a regressão linear múltipla. Este resultado mostrou a vantagem de se utilizar a técnica de redes neurais em problemas que envolvem a construção de modelos de previsão, conforme já previra Braga et al (2000, 227).

Entretanto, algumas ressalvas devem ser colocadas na obtenção deste resultado:

- 1) na construção do modelo da previsão de faturamento utilizando a regressão linear múltipla, foi utilizado a mesma amostra tanto para a validação como para o teste do modelo;
- 2) assim sendo, para a construção do modelo da previsão utilizando a rede MLP, cujo algoritmo de treinamento aplicado à rede foi *back propagation*, utilizou-

se o mesmo critério, isto é, o grupo de amostras utilizadas tanto no treinamento como para a validação e o teste foram as mesmas. Este procedimento sujeitou-se ao problema de *overfitting*, ou seja, a rede especializar nos padrões de treinamento e perder a sua capacidade de generalização (FREITAS e SOUZA, 2002). Por outro lado, observou-se que *overfitting* não ocorreu, pois que o erro quadrático absoluto não foi zerado em nenhum caso, mesmo após a execução de exaustivo treinamento.

- 3) poderia ter sido utilizado o *default* do software “Statistica – Neural Networks”, para se obter os grupos de amostras. O software utilizado, agrupa as amostras de treinamento, verificação e teste, na proporção: 2: 1: 1, aleatoriamente. Entretanto, essa opção foi descartada, uma vez que não houve o problema de *overfitting*, além disso, o que desejava com o estudo era apenas comparar o desempenho do modelo de previsão do faturamento baseados em regressões lineares e redes neurais.

Tabela 8: Comparação do Erro Quadrático Médio entre: Regressão Linear Múltipla e Redes Neurais

ANO	FATURAMENTO			ERRO QUADRÁTICO	
	Real	Regressão Linear Múltipla	Redes Neurais	Regressão Linear Múltipla	Redes Neurais
1980	100,00	97,9969	96,67582	4,012	11,050
1981	76,61	87,6650	76,58133	122,213	0,001
1982	87,86	85,8812	79,30425	3,916	73,155
1983	83,15	90,7380	84,84822	57,578	2,889
1984	81,86	90,0338	82,6855	66,811	0,687
1985	103,98	96,3677	100,3553	57,947	13,165
1986	99,68	94,7635	97,70482	24,172	3,914
1987	107,14	109,9589	103,6753	7,946	12,020
1988	120,97	107,4123	111,3614	183,811	92,295
1989	112,17	95,7024	99,63841	271,182	156,983
1990	83,64	85,5444	78,77602	3,627	23,661
1991	85,97	90,8822	92,68072	24,130	44,982
1992	106,78	114,2832	112,3834	56,298	31,447
1993	123,70	132,6600	128,4406	80,282	22,454
1994	148,01	151,3944	145,2427	11,454	7,671
1995	148,87	151,7303	146,1774	8,181	7,254
1996	160,82	158,5019	156,605	5,374	17,781
1997	176,34	185,6327	174,1102	86,354	4,971
1998	169,11	163,7369	162,1232	28,870	48,872
1999	140,50	132,8697	126,4433	58,221	197,451
2000	153,00	157,5644	154,0154	20,834	1,022
2001	180,57	169,4102	166,3424	124,541	202,519
TOTAL	2650,73	2650,73	2576,17	1307,754	976,245
	ERRO QUADRÁTICO MÉDIO			59,443	44,375

5 CONCLUSÕES

O resultado obtido neste estudo, mostrou que o modelo baseado em redes neurais superou o modelo de previsão base em regressão linear múltipla na previsão de faturamento da indústria automobilística. A superioridade do modelo em redes neurais, foi constatada no menor Erro Quadrático Médio. Outro resultado interessante que se observou, foi a não significância da variável “investimento” tanto quando se utilizou a regressão linear múltipla como redes neurais.

A semelhança dos resultados obtidos, a alternativa de modelagem por Redes Neurais Artificiais torna-se atraente, já que estas se caracterizam por uma modelagem não paramétrica, em que não há grande necessidade de se entender o processo propriamente dito. A modelagem pode ser feito utilizando-se somente amostragens de valores de entrada e saída do sistema em intervalos regulares, conforme afirma Braga et al (1998, 227).

Por fim, os resultados obtidos permitem sugerir que:

- a) o modelo em redes neurais representa um bom instrumento alternativo de previsão, e que podem ajudar os administradores nas tomadas de decisões e no planejamento estratégico organizacional e;
- b) (b) seja utilizado em estudos futuros, incorporando assim, ao acervo de conhecimento a serviço da ciência e tecnologia.

REFERÊNCIAS BIBLIOGRÁFICAS

ANFAVEA 2002. **Anuário Estatístico da Indústria Automobilística Brasileira**. São Paulo: Associação nacional dos fabricantes de Veículos Automotores, 2002.

BRAGA, Antônio de Pádua, LUDEMIR, Teresa Bernarda, CARVALHO, André Carlos Ponde de Leon Ferreira. **Redes Neurais e Artificiais, Teoria e Aplicações**. Rio de Janeiro: LTC Editora, 2000.

CARTACHO, Marcelo Soares; SOUZA, Antônio Artur. **A utilização de um modelo composto por algoritmos genéticos e redes neurais no processo de seleção de carteiras**. Salvador: XXVI ENANPAD 2002, 22 a 25 de setembro de 2002.

FREITAS, Sander Oliveira; SOUZA, Antônio Artur. **Utilização de um Modelo Baseado em Redes Neurais para a Precificação de Opções**. Salvador: XXVI ENANPAD 2002, 22 a 25 de setembro de 2002.

GUJARATI, Damodar N. **Econometria Básica**. São Paulo: Makron books. 2000.

HAYKIN, Simon. **Redes Neurais, Princípios e Prática**. Porto alegre: Editora Bookman, 2ª edição, 2001.

HILL, Carter, GRIFFITHS, William, JUDGE, George. **Econometria**. São Paulo: Ed. Saraiva, 2000.

LEVINE, David M., BERENSON, Mark L., STEPHAN, David. **Estatística: Teoria e Aplicações**. Rio de Janeiro, LTC, 2000.

LOESCH, Cláudio; SARI, Solange T. **Redes Neurais – Fundamentos e Modelos**. Blumenau: Editora da FURB, 1996.

MOLITERNO, D. **Montadoras prometem investir R\$ 95 bi no Brasil instigados por competição chinesa e programa do governo**. 2024, Disponível em: <<https://www.cnnbrasil.com.br/economia/macroeconomia/montadoras-prometem-investir-r-95-bi-no-brasil-instigados-por-competicao-chinesa-e-programa-do-governo/>>. Acesso em: 20/01/2025.

NASCIMENTO JR, Cairo L; YONEYAMA, Takashi. **Inteligência Artificial, em Controle e Automação**. São Paulo: Editora Edgard Blucher Ltda / FAPESP, 2000.

OHMAE, Kenichi. **Voltando à Estratégia**. Rio de Janeiro: Editora Campus, 2ª edição, 1998.

PORTUGAL, Marcelo S. & FERNANDEZ, Luiz G. L. **Redes Neurais Artificiais e Previsão de Séries Econômicas: Uma Introdução**, *mimeo*.

SILVA, Cleide. **Fábricas brasileiras estão entre as mais modernas**. São Paulo: OESP – Caderno de economia, indústria automobilística, 23 de julho de 2000, página B7.

SIMONSEN, Mario H. & CYSNE, Rubens C. **Macroeconomia**. Rio de Janeiro: Ed. FGV/Atlas, 1995.