

ESCOLA POLITÉCNICA DA UNIVERSIDADE DE SÃO PAULO

MÁRIO AUGUSTO NUNES DIAS

**REDES NEURAIS ARTIFICIAIS APLICADA AO
TRATAMENTO TÉRMICO DE LIGAS
DURALUMÍNIO**

São Paulo 2010

MÁRIO AUGUSTO NUNES DIAS

**REDES NEURAIS ARTIFICIAIS APLICADA AO
TRATAMENTO TÉRMICO DE LIGAS
DURALUMÍNIO**

Trabalho de Formatura apresentado à
Escola Politécnica da Universidade
de São Paulo

Área de Concentração : Engenharia de
Materiais

Orientador: Ronald Lesley Plaut

São Paulo 2010

Dedicatória

Ao meus pais que me apoiaram em toda esta saga, à minha namorada Juliana que me deu grande força para seguir em frente na minha formatura.

Agradecimentos

Ao Prof. Dr. Ronald Lesley Plaut pela paciência e grande ajuda na conclusão deste trabalho.

Resumo

Utilizando as Redes Neurais Artificiais do tipo Multilayer Perceptron, foram reconstruídas as curvas de envelhecimento para as ligas de alumínio 2014 e 2024 encontradas na Literatura Técnica.

Além disso esse trabalho fornece curvas de envelhecimento para as temperaturas intermediárias às disponíveis na literatura possibilitando a previsão do comportamento mecânico das ligas em questão para tratamentos térmicos intermediários aos tabelados na literatura.

Sumário

1. Objetivos.....	p.10
2. Revisão Bibliográfica e Fonte de Dados.....	p.11
3. Tratamento térmico de ligas de Alumínio.....	p.13
3.1.Introdução.....	p.13
3.2.Homogenização.....	p.14
3.3.Precipitação	p.16
3.4.Elementos de Liga.....	p.18
4. Ligas de Al-Cu (Duralumínio).....	p.19
4.1.Aplicações Comerciais.....	p.19
4.2.Endurecimento de Ligas Al-Cu.....	p.21
4.3.Ligas 2014 e 2024.....	p.24
5. Redes Neurais	p.26
5.1.Introdução.....	p.26
5.2.Tipos de Rede.....	p.27
5.3.Aplicações das redes neurais.....	p.29
6. Previsão de Curvas de Envelhecimento por Redes Neurais	p.30
6.1.Dados de Entrada.....	p.30
6.2.Construção da Rede Neural no NeuroSolutions para Excel....	p.34
6.3.Treinamento, Testes e Refino dos Dados de Entrada.....	p.39
6.4.Capacidade de generalização de uma rede neural.....	p.41
6.5.Análise das redes criadas.....	p.42
7. Recriação das Curvas de Envelhecimento pela Rede Neural.....	p.50
7.1.Produção dos dados (Production).....	p.50
7.2.Comparação das Curvas produzidas pela Rede Neural e Curvas da Literatura.....	p.52
7.3.Curvas para as temperaturas não fornecidas (interpolação de curvas).....	p.59
8. Conclusões.....	p.66
9. Sugestões para trabalhos futuros.....	p.67
ANEXO I	p.68

Referências

Lista de Gráficos

Gráfico 1. Curva de Envelhecimento da Liga 2014.....	p.12
Gráfico 2. Curva de Envelhecimento da Liga 2024.....	p.12
Gráfico 3 . Curvas de Envelhecimento Originais 2014.....	p.31
Grafico 4 . Curvas de Envelhecimento Originais 2024.....	p.33
Gráfico 5. Aprendizado da rede para liga 2014.....	p.42
Gráfico 6. Desempenho da rede para liga 2014.....	p.42
Grafico 7 .Análise de Sensibilidade liga 2014.....	p.44
Grafico 8 .Análise de Sensibilidade da Temperautra Liga 2014.....	p.44
Grafico 9. Análise de Sensibilidade do Tempo Liga 2014.....	p.45
Gráfico 10 . Aprendizado da rede para liga 2024.....	p.46
Gráfico 11. Desempenho da rede para liga 2024.....	p.47
Grafico 12 .Análise de Sensibilidade liga 2024.....	p.48
Grafico 13 .Análise de Sensibilidade da Temperautra Liga 2024.....	p.48
Grafico 14. Análise de Sensibilidade do Tempo Liga 2024.....	p.49
Gráfico 15. Sobreposição de curvas a 135°C – Liga 2014.....	p.54
Gráfico 16. Sobreposição de curvas a 190°C – Liga 2014.....	p.54
Gráfico 17. Sobreposição de curvas a 205°C – Liga 2014.....	p.55
Gráfico 18. Sobreposição de curvas a 130°C – Liga 2024.....	p.57
Gráfico 19. Sobreposição de curvas a 190°C – Liga 2024.....	p.57
Gráfico 20. Sobreposição de curvas a 205°C – Liga 2024.....	p.58
Gráfico 21. Curvas de criadas por RNA de 105°C a 135 °C - liga 2014.....	p.60
Gráfico 22. Curvas de criadas por RNA de 140°C a 175 °C - liga 2014.....	p.60
Gráfico 23. Curvas de criadas por RNA de 180°C a 205 °C - liga 2014.....	p.61
Gráfico 24. Curvas de criadas por RNA de 210°C a 260 °C - liga 2014.....	p.61
Gráfico 25. Superfície criada por RNA (vista a 45°) - liga 2014.....	p.62
Gráfico 26. Superfície criada por RNA (vista a 90°) - liga 2014.....	p.62
Gráfico 27. Curvas de criadas por RNA de 100°C a 145 °C - Liga 2024.....	p.63

Gráfico 28. Curvas de criadas por RNA de 150°C a 170 °C - Liga 2024.....	p.63
Gráfico 29. Curvas de criadas por RNA de 175°C a 195 °C - Liga 2024.....	p.64
Gráfico 30. Curvas de criadas por RNA de 200°C a 250 °C - Liga 2024.....	p.64
Gráfico 31. Superfície criada por RNA (vista a 115°) - Liga 2024.....	p.65
Gráfico 32. Superfície criada por RNA (vista a 90°) - Liga 2024.....	p.65

Lista de Figuras e Tabelas

Figura 1. Esquema do processo de solubilização.....	p.15
Figura 2. Esquema do processo de solubilização e Precipitação.....	p.17
Figura 3. Representação esquemática do processo de precipitação.	p.22
Figura 4. Micrografia das etapas de precipitação de Liga Al-Cu.....	p.23
Figura 5: Organização de uma rede neural.....	p.26
Figura 6. Tela de classificação de Colunas Neurosolutions.....	p.34
Figura 7. Janela para escolha do Modelo de Rede Neural.....	p.36
Figura 8. Arquitetura da Rede Neural.....	p.36
Figura 9. Configuração da Camada Intermediária.....	p.37
Figura 10. Configuração da Camada de Saída.....	p.37
Figura 11. Critério de Parada.....	p.38
Tabela 1. Resumo de ligas da Séries 2000 mais comuns.....	p.20
Tabela 2. Composição Química das Ligae 2014 e 2024.....	p.24
Tabela 3. Propriedades Mecânicas Típicas da Liga 2014 T6 ou T651 em várias temperaturas.....	p.25
Tabela 4. Propriedades Mecânicas Típicas da Liga 2024 T6 ou T651.....	p.25
Tabela 5. Aprendizado da rede para liga 2014.....	p.42
Tabela 6 . Desempenho da rede para liga 2014.....	p.43
Tabela7 . Aprendizado da rede para liga 2024.....	p.46
Tabela 8 . Desempenho da rede para liga 2024.....	p.47
Tabela 9. Análise Comparativa de dados produzidos X originais 2014.....	p.53
Tabela 10. Análise Comparativa de dados produzidos X originais 2024.....	p.56

1. Objetivos

Utilizando as Redes Neurais Artificiais, reconstruir as curvas de envelhecimento para as ligas 2014 e 2024 encontradas na Literatura Técnica e também criar as curvas de envelhecimento para as temperaturas intermediárias não disponíveis na literatura.

2. Revisão Bibliográfica e Fonte de Dados

Existem muitos estudos da aplicação das Redes Neurais para otimização de processos produtivos e estudos da utilização de Redes Neurais para tentar prever o comportamento dos materiais.

A verificação e previsão do comportamento mecânico de ligas de Magnésio⁽¹⁾ e Alumínio⁽²⁾ através da utilização de Redes Neurais aplicada aos parâmetros de produção e de tratamento térmico é razoavelmente bem sucedida e pode-se constatar que as Redes Neurais geradas para estas finalidades tem ótima capacidade de generalização conseguindo prever as características dos materiais com boa aproximação

No trabalho de Carlini⁽³⁾, temos uma apresentação resumida dos principais arquiteturas de redes neurais e funções de transferência, testando-as para dois diferentes tipos de aços. Neste trabalho verificou-se que a rede de melhor desempenho foi a Multilayer Perceptron (MLP) com função de transferência Tanh Axon.

Outro trabalho interessante é o estudo do tratamento térmico de bronzinas cujas ligas de interesse são as AlCuSiSn⁽⁴⁾, esse trabalho evidencia a incapacidade das Redes Neurais de entenderem fenômenos metalúrgicos a partir de uma base de dados de aprendizado muito pequena.

Não se tem um valor base do número de dados de entrada ótimo, mas levanta-se o número 1000 com sendo um valor em que a sua Rede Neural funcionaria. No trabalho mencionado acima foi utilizada uma base de dados contendo 33 amostras triplicadas, isto é, 99 dados de entrada para o treinamento da rede neural.

Porém fica constatada a limitação da Rede Neural em extrapolar os resultados para valores fora dos dados de entrada do aprendizado⁽⁵⁾ uma maneira de contornar essa limitação é a combinação de modelos fenomenológicos e suas equações constitutivas aliado a capacidade de aprendizado das Redes Neurais⁽⁶⁾. Essa combinação é muito poderosa e possibilita com poucos dados experimentais treinar a Rede Neural tanto com

valores experimentais como com valores produzidos pelas equações fenomenológicas associadas.

As curvas de estudo neste trabalho serão as curvas de envelhecimento das ligas 2014 e 2024 que foram retiradas do Metals Handbook ⁽⁷⁾, vistos abaixo no Gráfico 1 e Gráfico 2 respectivamente.




Gráfico 1. Curva de Envelhecimento da Liga 2014




Gráfico 2. Curva de Envelhecimento da Liga 2024

3. Tratamento Térmico Para Aumento de Ligas de Alumínio⁽⁷⁾⁽⁸⁾⁽⁹⁾⁽¹⁰⁾

3.1. Introdução

O tratamento térmico é toda operação que envolve aquecimento e/ou resfriamento em diferentes velocidades e graus para se alterar a estrutura e propriedades das ligas metálicas. Em se tratando de Alumínio geralmente após operações de tratamento térmico o objetivo quase sempre é elevar a resistência mecânica da liga.

As ligas de Alumínio podem ser divididas em 2 classes, a primeira engloba as ligas não tratáveis termicamente, isto é, suas propriedades mecânicas não podem ser elevadas submetendo-as a algum tipo de tratamento térmico e a segunda classe engloba as ligas que podem ser tratadas termicamente e após o tratamento térmico suas propriedades de resistência mecânica são elevadas substancialmente.

Basicamente, a característica de ter suas propriedades mecânicas alteradas pelo tratamento térmico está associada aos elementos de liga presentes nas ligas de Alumínio. (ver seção 3.4)

Os dois principais tratamentos térmicos de ligas de Alumínio são a homogeneização ou solubilização e a precipitação a partir de solução sólida, comumente conhecida por precipitação ou envelhecimento, que serão detalhados a seguir.

3.2. Homogenização

Para poder endurecer uma liga de Alumínio a partir de uma reação de precipitação em solução sólida (Precipitação ou Envelhecimento) primeiro precisa-se criar uma solução sólida na liga em questão, esta etapa é chamada de solubilização ou homogenização e tem como objetivo solubilizar o máximo de componentes que formam precipitados de endurecimento presentes na liga criando assim uma solução sólida mais homogênea possível.

Estruturas brutas de fundição são geralmente formadas por uma estrutura dendrítica que são acompanhadas de grandes segregações químicas. Antes de qualquer processo de conformação mecânica é desejado que a estrutura dendrítica seja reduzida a um nível aceitável e que a segregação da composição química seja reduzida ao seu mínimo. Então através do processo de Homogenização, obtém-se o máximo de redução da estrutura dendrítica bem como o mínimo de segregação da composição.

A Homogenização consiste em aquecer a liga até uma temperatura alta, isto é, bem próximo da temperatura de fusão para que os átomos ganhem grande mobilidade e possam difundir pela rede atômica fazendo com que os componentes químicos que estavam segregados (agrupados) difundam para regiões pobres homogenizando a composição em todos os pontos.

Por causa da temperatura elevada uma mudança da microestrutura é observada, o aquecimento permite que os átomos se reorganizem fazendo com que a estrutura bruta de fundição dendrítica se reduza substancialmente pela recristalização da microestrutura.

As estruturas brutas de fundição ou mesmo as estruturas produzidas por transformação mecânica geralmente apresentam precipitados de tamanho indesejável ou dispersos de uma maneira não muito desejada, e para resolver este problema a Homogenização entra em ação para fazer com que esses precipitados indesejados desapareçam da rede pela dissolução dos mesmos criando assim uma solução sólida, por isso a Homogenização também pode ser chama de Solubilização.

A Homogenização ou solubilização sozinha não garante que os precipitados dissolvidos não voltem a precipitar indesejavelmente, para isso após a solubilização dos precipitados (após a etapa de Homogenização) é necessária uma etapa de têmpera (muito similar à tempera de aços), isto é, necessita-se de uma etapa de rápido resfriamento para garantir que a solução sólida “congele” nessa configuração e mantendo-se supersaturada pelo soluto impedindo, assim, a precipitação dos solutos em solução sólida.

Abaixo temos um resumo esquemático de como ocorre o processo de solubilização.




Figura 1. Esquema do processo de solubilização

3.3. Precipitação

Geralmente uma forma para se obter uma liga de máxima de resistência mecânica é pela produção de uma liga cuja microestrutura apresente dispersa em sua matriz dúctil finas partículas de precipitados que impeçam a movimentação de discordâncias, quando mais fina sejam as partículas e quanto melhor a sua dispersão maior a resistência mecânica da liga.

Uma forma de se obter essa fina dispersão de precipitados é através do tratamento térmico de precipitação em solução sólida.

O mecanismo de endurecimento por precipitados pode ser de duas formas. Caso o precipitado seja um precipitado coerente com a matriz (não existe contorno de grão, isto é, o precipitado está no mesmo cristal da matriz) o mecanismo de endurecimento (aumento de resistência) ocorre por causa da deformação que o precipitado coerente causa no reticulado cristalino na matriz levando a uma aniquilação ou estabilização de discordâncias, então como o a liga apresenta menos defeitos internos ou a mobilidade das discordâncias é de certa forma retardada a liga tem uma resistência mecânica mais elevada.

Agora, caso o precipitado seja semi-coerente ou incoerente (existe um contorno de grão, isto é, existe uma interface entre o precipitado e a matriz), o mecanismo de endurecimento ocorre por que as discordâncias tem que passar pelo precipitado contornando-o e esse trabalho necessário para que as discordâncias contornem os precipitados também resulta em um aumento de resistência mecânica da liga. Abaixo vemos um esquema do processo de precipitação precedido de solubilização:




Figura 2. Esquema do processo de solubilização e Precipitação

3.4. Elementos de Liga

Os principais elementos de liga das ligas de Alumínio são: Cobre, Magnésio, Manganês, Silício, e Zinco. A Classificação das ligas de Alumínio são feitas de acordo com os elementos de liga.

- 1xxx – Alumínio comercialmente puro
- 2xxx – Alumínio + Cobre (**Tratável termicamente**)
- 3xxx – Alumínio + Manganês
- 4xxx – Alumínio + Silício
- 5xxx – Alumínio + Magnésio
- 6xxx – Alumínio + Silício + Magnésio (**Tratável Termicamente**)
- 7xxx – Alumínio + Zinco (**Tratável Termicamente**)
- 8xxx – Alumínio + Lítio ou outros (algumas ligas são tratáveis termicamente)

Basicamente apenas os elementos de liga cobre, silício associado ao magnésio e zinco possibilitam o endurecimento das ligas de Alumínio por tratamento térmico de precipitação ou envelhecimento.

Neste trabalho serão estudadas mais a fundo as ligas de Alumínio e Cobre, conhecidas comercialmente pelo nome de Duralumínio. Estas ligas são tratáveis termicamente e podem apresentar resistências de escoamento superiores a 400 Mpa. Em especial esse trabalho enfocará as ligas 2014 e 2024, que foram muito usadas na produção de aviões comerciais e militares nos últimos anos mas agora estão caindo em desuso devido ao desenvolvimento de ligas mais resistentes.

4. Ligas de Al-Cu (Duralumínio)

4.1. Aplicações Comerciais

O Cobre é adicionado à ligas de Alumínio quando se deseja aumentar a sua resistência mecânica. Adições crescentes de Cobre ao Alumínio aumentam tanto sua dureza e resistência mecânica quando aumentam a ductilidade da liga, mas esses incrementos de propriedades são alcançados somente se o cobre estiver disperso de uma forma particular na microestrutura da liga, essa dispersão adequada é conseguida através de processos de tratamento térmico de precipitação.

As aplicações comerciais das ligas da série 2000 ou conhecidas como Duralumínio são diversas mas são usadas especialmente quando se necessita uma relação Resistência Mecânica/Peso alta, isto é, quando o componente onde a liga vai ser empregada deve ser resistente porém leve. Em algumas ligas da série 2000 pode-se obter resistência superior a de aços de baixo carbono.

Os Duralumínios têm características de corrosão relativamente pobres, podem em alguns casos sofrer corrosão no contorno de grão e geralmente chapas de ligas de Duralumínio são colaminadas ou unidas a chapas de alumínio puro ou ligas da série 6000 para adquirirem proteção galvânica.

Além disso, exceto pela liga 2219 as ligas dessa família são bem difíceis de serem soldadas porém a usinabilidade dos Duralumínios são excelentes.

As ligas da série 2000 são adequadas para fabricação de estruturas de alto coeficiente de resistência/peso e são comumente utilizadas em rodas e suspensões de caminhões e aviões, fuselagem e cobertura de asas de aviões, parafusos leves de alta resistência, extrudados estruturais, chapas para carroceria automotiva, chaparia estrutural de ônibus e caminhões, forjados, pistões e cabeçotes de motores a diesel e outras aplicações que necessitem de resistência a altas temperaturas (acima de 150°C). Na tabela abaixo temos um panorama de aplicações e resistências típicas das ligas da série 2000.

Liga	Aplicações	Limite de Escoamento Típico
2011	Parafusos de Alta resistência	T3 - 296 MPa
2014	Forjados de alta resistência, chapas e extrudados estruturais para aviação, rodas e grandes peças estruturais, suspensão de caminhões e aplicações que necessitem resistência a alta temperatura	T4 - 290 Mpa T6 - 440 MPa
2017	Primeira liga desenvolvida para aplicações aeronáuticas. Está caindo em desuso e só tem sido usada em rebites e parafusos de alta resistência	T4 - 275 Mpa
2024	Estruturas de aviões, rebites, rodas de caminhões, parafusos e aplicações estruturais diversas	T3 - 345 MPa T6 - 393 MPa T81 - 448 MPa T861 - 490 MPa
2036	Chapas para carrocerias automobilísticas	T4 - 195 MPa
2048	Chapas e placas para componentes estruturais de equipamentos aeroespaciais e militares	406 MPa
2090	Estruturas aeronáuticas	T83 - 455MPa *ALCOA
2124	Estruturas aeronáuticas	T851 - 420MPa
2218	Forjados, pistões e motores a diesel, cabeçotes de motores aeronáuticos.	T61 - 303 MPa T71 - 276 MPa
2219	Componentes e fuselagem de aviões supersônicos, elementos soldados de foguetes espaciais e elementos de soldagem. Alta resistência a Fratura	T31 - 248 MPa T37 - 317 MPa T42 - 186 MPa T62 - 290 MPa T81 - 352 MPa T87 - 393 Mpa
2319	Eletrodos e elementos de preenchimento de solda para liga 2219	Não definida
2618	Forjados, molde de pneus, pistões e motores aeronauticos, outras aplicações em altas temperaturas	T61 - 372 MPa

Tabela 1. Resumo de ligas da Séries 2000 mais comuns

4.2 Endurecimento de Ligas Al-Cu

O requisito básico necessário para endurecimento ou aumento de resistência de uma solução sólida supersaturada envolve a formação de um precipitado finamente disperso durante o tratamento térmico de envelhecimento (natural ou artificial).

Guinier-Preston (G-P ou GP) é uma pequena zona de uma solução sólida supersaturada que não tem estrutura cristalina própria definida e que contém concentração anormal de um soluto.

A formação de zonas GP constitui o primeiro estágio da precipitação que nada mais é que a formação de clusters (zonas) de átomos do soluto na solução sólida que mantém a mesma estrutura cristalográfica da solução mas pelo fato dos átomos do soluto terem tamanho diferente dos átomos da matriz causam uma grande distorção na rede cristalográfica da solução. A formação de precipitados coerentes ou incoerentes está ligada ao grau de diferença entre o átomo dos solutos e da matriz, quanto mais próximo um do outro maior a chance de se tornar um precipitado coerente.

As zonas GP têm unidade de grandeza da ordem de dezenas de ângstrons de diâmetro. Não são partículas discretas de uma nova fase, pelo contrário, são essencialmente regiões distorcidas da matriz e não tem contorno bem definido e por isso são totalmente coerentes com a matriz impondo nessas áreas grandes tensões e deformações no reticulado ao seu redor. Essas deformações mecânicas, assim como a presença de áreas de grande concentração do soluto que não alteraram significativamente a microestrutura da liga podem propiciar substanciais mudanças nas propriedades mecânicas.

A decomposição de uma solução sólida de ligas de Al-Cu pode ser prevista razoavelmente bem a partir do diagrama de fases Al-Cu ou sistemas mais complexos.

Uma solução sólida de Al-Cu decompõe-se nas seguintes fases: θ'' , θ' e θ (Al_2Cu). Essas fases são respectivamente coerente, semicoerente e incoerente (fase estável). Antes da precipitação da fase θ'' a zona GP é formada na solução sólida e geralmente a partir dela formam-se os precipitados

coerentes θ'' que tem formato de discos. Essas fases metaestáveis intermediárias θ'' e θ' são consideradas partículas apesar de serem coerentes e semicoerentes com a matriz, diferentemente das zonas GP que não tem características de precipitado ou partícula por não possuírem contornos definidos. Essas zonas GP são na realidade áreas em que há uma concentração anormal do soluto causando assim uma distorção da rede cristalográfica naquela região.

De maneira simplificada pode-se resumir o processo de precipitação nas seguintes fases :

Solução Sólida $\rightarrow$ Zonas GP $\rightarrow$ θ'' $\rightarrow$ θ' $\rightarrow$ θ (Al_2Cu) estável

As fases θ'' , θ' e θ de Al_2Cu são as fases coerente, semicoerente e incoerente, sendo que somente esta última é a fase estável, as outras são fases metaestáveis.




Figura 3. Representação esquemática do processo de precipitação.

(a) Estágio inicial. (b) Formação de zona GP e precipitado coerente θ'' . (c) Precipitado Semicoerente θ' . (d) Precipitado incoerente de equilíbrio θ .




Figura 4. Micrografia das etapas de precipitação de Liga Al-Cu

**(a) Formação de Zonas GP a 720.000x (b) θ'' a 63.000X, coerente
(c) θ' a 18.000X, semicoerente (d) θ a 8.000x, incoerente estável**

Para maximizar o endurecimento da liga o tratamento térmico é realizado até atingir uma etapa intermediária entre θ'' e θ' porque a distorção no espaçamento de rede que estes precipitados acarretam são ideais para retardar ou bloquear o movimento das discordâncias. Tratamentos térmicos realizados além da resistência mecânica máxima possível são chamados de super envelhecimento e geralmente não são desejáveis. No estado super envelhecimento há uma perda de propriedades mecânicas devido ao aumento do tamanho dos precipitados e do aumento do espaçamento entre eles.

Em ligas Al-Cu-Mg como as ligas 2024 e 2014 estudadas neste trabalho obtém um ganho a mais no aumento da resistência mecânica pelo fato de que o Magnésio promove, refina e estabiliza a formação da fase θ' favorecendo o uso da liga em temperaturas elevadas sem perda de resistência mecânica.

Nas ligas de Duralumínio contendo Magnésio são precipitadas as fases θ (Al_2Cu) discutida anteriormente e a fase S (Al_2CuMg) que é formada a partir de clusters da solução sólida contendo concentração elevada de Mg e Cu, esses clusters de Mg e Cu são chamados de Zona de Guinier-Preston-Bagaryatsky (GPB) que são similares a Zona Guinier-Preston.

Nessas ligas contendo Magnésio a formação de θ ou S depende da proporção entre magnésio e cobre e depende também da temperatura de envelhecimento, no entanto, o máximo da resistência mecânica ocorre quando a precipitação produz precipitados θ' e S'' para temperaturas mais baixas (130 a 165°C) e θ' , S'' e S' para temperaturas mais altas (190°C).

4.3 Ligas 2014 e 2024

As composições e propriedades mecânicas típicas das Ligas 2024 e 2014 estudadas neste trabalho seguem abaixo.

Grade designation				Composition, wt%														
Aluminum Association	UNS No.	ISO R109	No.	Si	Fe	Cu	Mn	Mg	Cr	Ni	Zn	Ga	V	Specified other elements	Ti	Unspecified other elements		Al, minimum
																Each	Total	
2014	A192014	AlCu45Mg		0.50-1.2	0.7	3.9-5.0	0.40-1.2	0.20-0.8	0.10	...	0.25	...	...	^	0.15	0.05	0.15	rem.
2024	A92024	AlCu4Mg1		0.50	0.50	3.8-4.8	0.30-0.9	1.2-1.8	0.10	...	0.25	...	...	^	0.15	0.05	0.15	rem.

Tabela 2. Composição Química das Ligas 2014 e 2024. ⁽⁸⁾

Temperature		Tensile strength		Yield strength ^(a)		Elongation, %
°C	°F	MPa	ksi	MPa	ksi	
-196	-320	579	84	496	72	14
-80	-112	510	74	448	65	13
-28	-18	496	72	427	62	13
24	75	483	70	414	60	13
100	212	439	63	393	57	15
149	300	276	40	241	35	20
204	400	110	16	90	13	38
260	500	66	9.5	52	7.5	52

Tabela 3. Propriedades Mecânicas Típicas da Liga 2014 T6 ou T651. ⁽⁸⁾

Temperature		Tensile strength		Yield strength (0.2% offset)		Elongation, %
°C	°F	MPa	ksi	MPa	ksi	
-196	-320	579	84	469	68	11
-80	-112	496	72	407	59	10
-28	-18	483	70	400	58	10
24	75	476	69	393	57	10
100	212	448	65	372	54	10
149	300	310	45	248	36	17
204	400	179	26	151	19	27
260	500	76	11	62	9	55
316	600	52	7.5	41	6	75
371	700	31	5	28	4	100

Tabela 4. Propriedades Mecânicas Típicas da Liga 2024 T6 ou T651. ⁽⁸⁾

5. Redes Neurais

5.1 Introdução

Redes neurais artificiais são redes matemáticas computacionais que tentam imitar o funcionamento do cérebro humano reconhecendo padrões de uma coletânea de dados..

A rede neural artificial imita o comportamento do cérebro natural inteligente natural pela sua habilidade de aprender e fazer descobertas autonomamente. Essa rede neural é bastante simples e os elementos dessa rede se conectam uns aos outros através de funções de conexão ou transferência e cada elemento está associado a um peso de ponderamento que permitirão a rede aprender relações entre variáveis de entrada e saída que geralmente não são claras ou não tem relação matemática analítica entre si.

Toda a rede neural tem a seguinte organização:




Figura 5: Organização de uma rede neural

Camada de entrada: Apresentação dos dados de entrada a rede

Camadas intermediárias: Realização do processamento através de conexões ponderadas.

Camada de Saída: Apresentação do resultado.

A rede em si é bastante simples mas cada camada intermediária e cada neurônio artificial é na verdade uma complexa combinação de funções matemáticas associadas a coeficientes de ponderação ou pesos, que atua de forma a relacionar os dados de entrada aos dados de saída.

As etapas para criação para uma rede neural artificial podem ser divididas em 4 etapas. Na primeira define-se o tipo de rede que se pretende utilizar e quais as funções de relacionamento entre as camadas e os nós

Numa segunda etapa faz-se o treinamento da rede, isto é, apresenta-se à rede pela primeira vez uma batelada de dados para que ela comece a entender as relações entre dados de entrada, nesta etapa o erro do modelamento é reduzido ao seu mínimo.

A terceira etapa é a etapa de validação em que a capacidade de generalização da rede é testada, isto é, apresentam-se dados à rede que não foram apresentados na etapa de treinamento e então verifica-se sua capacidade de entendê-los.

Na quarta etapa checa-se o desempenho global da rede testando com uma terceira batelada de dados não apresentados anteriormente para verificar o erro gerado pela rede.

5.2. Tipos de Rede

As principais arquiteturas de rede são as seguintes:

Multilayer Perceptron (MLP): É uma rede que utilize mecanismos de alimentação “avante” treinada com retro propagação. Pode ser utilizada praticamente em quaisquer tipos de dados de entrada e saída, mas apesar de

ser uma das mais robustas redes neurais sua principal desvantagem é a baixa velocidade de treinamento.

Generalized Feed Forward (GFF): É uma generalização da rede MLP, com a diferença que nesta rede pode-se saltar uma ou mais camadas intermediárias. Essa rede tende a ser mais eficiente e mais rápida que a MLP.

Modular Neural Network (MNN): É uma rede que utiliza duas ou mais redes MLP em paralelo. Também tende a ser mais eficiente e mais rápida que a MLP.

Jordan / Elman Network (JE): É mais uma evolução da MLP realimentando o sistema com mais de uma informação. A camada Elman Network envia informações da primeira camada intermediária para a entrada da rede e a Jordan Network envia os dados de saída alimentando-os com os dados de saída e intermediário ao mesmo tempo. Esta rede tem a habilidade de tratar dados temporais e seu contexto associando etapas do processamento com dados do passado.

Principal Component Analysis (PCA): Tem como característica principal fazer uma análise prévia dos dados de entrada encontrando os valores discrepantes, repassando os dados de entrada tratados para processamento em uma MLP.

Radial Basis Function (RBF): É uma rede não linear que contém tipicamente uma camada intermediária e usa funções de transferência gaussiana ao invés das funções sigmodais padrão. É uma rede que tende a aprender mais rapidamente que a MLP.

No âmbito deste trabalho apenas a rede MLP pela sua robustez e alta capacidade de processar problemas variados mesmo com pequena quantidade de dados de entrada.

5.3. Aplicações de Redes Neurais

As Redes Neurais Artificiais são uma ferramenta muito poderosa no processamento de problemas, não somente em problemas matemáticos mas também problemas de causa e feito.

Algumas das várias aplicações que se pode citar são:

Reconhecimento de voz: Aplicado a redes de telecomunicação para acesso de menus e serviços.

Reconhecimento de caracteres (OCR): Aplicado a leitura de documentos e leituras de placas de carros.

Análise de mercado de ações: Para tentar prever o comportamento dos preços das ações melhorando a rentabilidade dos fundos de ações.

Diagnóstico médico: Aplicando Redes Neurais para aprender as relações entre sintomas e doenças de um grupo de pacientes pode-se chegar a um diagnóstico mais preciso

Diagnóstico de processos e máquinas: Permite diagnosticar falhas no processo produtivo ou falhas de equipamentos antes que elas ocorram.

Deteção de Fraudes: Algumas empresas de cartão de crédito utiliza Rede Neural para reconhecer padrões de fraudulentos do uso do cartão de crédito baseado nos dados de utilização dos cartões.

Na área metalúrgica seu uso ainda está no início mas os estudos mais recentes mostram um potencial muito grande tanto na área de controle de processo quanto na área de previsão das propriedades dos materiais.

Além disso, a Rede Neural pode ser utilizada também para otimizar os processos quanto à sua eficiência financeira tornando os processos produtivos metalúrgicos eficientes em termos de retorno financeiro além de eficiente em termos de obter as propriedades desejadas do processo.

6. Previsão de Curvas de Envelhecimento por Redes Neurais

6.1 Dados de Entrada

Os dados de entrada para processamento na rede neural retirados das curvas de envelhecimento apresentadas no Metals Handbook [5] pág. 1919 e 1920, vistas anteriormente no Cap. 2

Dados de Entrada da Liga 2014

Temperatura °C	Tempo (Hrs)	Resistência (Mpa)	Temperatura °C	Tempo (Hrs)	Resistência (Mpa)	Temperatura °C	Tempo (Hrs)	Resistência (Mpa)
105	1	245	175	1	300	205	0,1	255
105	2	245	175	2	365	205	0,25	335
105	4	250	175	4	415	205	1	390
105	6	250	175	6	420	205	2	400
105	8	250	175	8	420	205	4	385
105	10	255	175	10	420	205	6	375
105	15	255	175	15	415	205	8	365
105	25	260	175	25	410	205	10	355
105	40	265	175	40	395	205	15	345
105	65	270	175	65	380	205	25	315
105	100	275	175	100	365	205	40	280
105	200	290	175	200	340	205	65	240
105	500	305	175	500	290	205	100	210
105	1000	330	175	1000	230	205	200	180
105	5000	425	190	0,1	215	205	500	155
135	1	220	190	0,25	250	230	0,1	365
135	2	220	190	1	350	230	0,25	375
135	4	225	190	2	385	230	1	350
135	6	225	190	4	400	230	2	320
135	8	230	190	6	395	230	4	290
135	10	230	190	8	390	230	6	275
135	15	235	190	10	380	230	8	260
135	25	245	190	15	375	230	10	245
135	40	310	190	25	355	230	15	225
135	65	390	190	40	335	230	25	195
135	100	405	190	65	310	230	40	175
135	200	410	190	100	285	230	65	155
135	500	390	190	200	245	230	100	140
135	1000	360	190	500	190	260	0,1	335
150	1	245				260	0,25	310
150	2	245				260	1	245
150	4	250				260	2	210
150	6	300				260	4	180
150	8	340				260	6	165
150	10	365				260	8	155
150	15	400				260	10	150
150	25	420				260	15	135
150	40	425				260	25	125
150	65	420				260	40	115
150	100	410				260	65	110
150	200	390				260	100	105
150	500	360						
150	1000	320						




Gráfico 3 . Curvas de Envelhecimento Originais 2014

Dados de Entrada da Liga 2024

Temperatura °C	Tempo (Hrs)	Resistência (Mpa)
100	1	345
100	2	345
100	4	345
100	6	345
100	8	345
100	10	345
100	15	345
100	25	345
100	40	345
100	65	345
100	100	345
100	200	345
100	500	345
100	1000	345
130	1	345
130	2	345
130	4	345
130	6	345
130	8	345
130	10	345
130	15	345
130	25	345
130	40	345
130	65	345
130	100	345
130	200	355
130	500	385
130	1000	420
150	1	325
150	2	330
150	4	330
150	6	335
150	8	335
150	10	340
150	15	345
150	25	350
150	40	365
150	65	375
150	100	400
150	200	450
150	500	460
150	1000	450

Temperatura °C	Tempo (Hrs)	Resistência (Mpa)
160	1	320
160	2	320
160	4	325
160	6	325
160	8	330
160	10	330
160	15	340
160	25	350
160	40	375
160	65	400
160	100	425
160	200	395
160	500	360
160	1000	320
190	1	325
190	2	345
190	4	385
190	6	420
190	8	450
190	10	460
190	15	440
190	25	390
190	40	360
190	65	340
190	100	330
190	200	315
175	1	320
175	2	320
175	4	335
175	6	350
175	8	365
175	10	370
175	15	395
175	25	430
175	40	435
175	65	420
175	100	400
175	200	370

Temperatura °C	Tempo (Hrs)	Resistência (Mpa)
205	1	360
205	2	420
205	4	430
205	6	430
205	8	425
205	10	420
205	15	410
205	25	400
205	40	390
205	65	380
205	100	375
205	200	360
205	500	330
205	1000	305
260	1	385
260	2	370
260	4	340
260	6	320
260	8	305
260	10	290
260	15	270
260	25	240
260	40	220
260	65	190
260	100	175
260	200	150
260	500	130
260	1000	110




Grafico 4 . Curvas de Envelhecimento Originais 2024

6.2. Construção da Rede Neural no NeuroSolutions para Excel

O software utilizado neste trabalho para criação de uma rede neural foi o software Neurosolutions para Microsoft Excel na versão 6.0 para avaliação. Este software é bastante simples e “user-friendly” facilitando a vida do usuário utilizando interface gráfica intuitiva e comandos simples.

Primeiramente abre-se a base de dados no Neurosolutions para Excel para configuração e escolha da arquitetura da rede a ser utilizada.

A classificação dos dados de entrada e saída para treinamento da rede é a primeira etapa para criação da rede e é feita escolhendo-se as colunas de dados de entrada e classificando-as como **Column as input** e os dados de saída para treinamento como **Column as desired**, as colunas ficarão em azul quando a classificação é feita, sendo que as colunas de saída estarão em negrito.

Procedendo como nos passos mencionados acima as colunas de Temperatura e Tempo, referentes ao tratamento térmico foram classificadas como entradas (input) e a coluna de Escoamento, que representa a tensão de escoamento para cada condição de tratamento térmico foi classificada como saída (desired) que ficou em negrito.




Figura 6. Tela de classificação de Colunas Neurosolutions

Após a definição dos dados de entrada e saída é necessário randomizar os valores nas colunas para que a rede possa percorrer todos os dados de maneira aleatória evitando erros de aprendizado. Para realizar esta randomização basta acessar a ferramenta **Radomize Rows** no item do menu **Preprocess Data**.

Uma vez que os dados estão classificados quanto a entradas e saídas desejadas e estão randomizados é necessário fazer uma nova classificação agora uma classificação nas linhas. Essa classificação nas linhas é feita de maneira a separar os dados em dados de treinamento, validação e testes. A classificação dos dados de entrada e saída desejada nessas 3 baterias de dados é o que fará com que a rede aprenda o comportamento desejado.

Para fazer essa classificação é necessário dividir os dados na proporção de 8:1:1 ou seja 80% dos dados iniciais devem ser classificados como dados de treinamento (**Row(s) as Training**), 10% deve ser classificado como validação (**Row(s) as CrossValidation**), e 10 % como dados de teste (**Row(s) as Testing**).

Após a classificação dos dados para treino da rede é preciso configurar a arquitetura da rede a ser utilizada. Para isto abre-se na aba do Neurosolutions no Excel a opção **Create/Open Network** e então abre-se a opção **New Custon Network**.

Uma janela, mostrada na Figura 5, abre-se automaticamente para escolha do modelo de rede. Neste trabalho será utilizada a rede Multilayer Perceptron, pelas sua robustez em conseguir processar os mais variados problemas apresentado resultados muito satisfatórios.




Figura 7. Janela para escolha do Modelo de Rede Neural

Após a escolha do tipo de rede deve-se escolher a arquitetura dela, isto é, suas camadas internas e nós. Uma segunda janela abre-se automaticamente para estas seleções, visto na Figura 6.




Figura 8. Arquitetura da Rede Neural

Nesta etapa foi configurada uma rede com apenas uma camada intermediária, 2 elementos de entrada e 1 de saída foram definidos na classificação das colunas na etapa anterior.

No próximo passo, escolhemos o número de nós, a função de transferência e o método de aprendizado da rede neural como mostrado na Figura 7.




Figura 9. Configuração da Camada Intermediária

Na da camada de saída da rede neural foi pré-selecionado o valor 1 de acordo com as classificações das colunas que fizemos anteriormente, os métodos de aprendizado e função de transferência fora mantidos iguais para camadas intermediárias e camada de saída, ver Figura 8.




Figura 10. Configuração da Camada de Saída

Após configurarmos toda rede, precisa-se configurar um critério de parada do aprendizado. Foi escolhido o critério de número de iterações máximo como critério de parada, e o número de iterações foi 500. Visto na figura 9.




Figura 11. Critério de Parada

Após esta etapa a rede está totalmente configurada e pronta para executar a etapa de aprendizado utilizando os valores de entrada.

6.3 Treinamento, Testes e Refino dos Dados de Entrada

Após a configuração da rede foi feito um primeiro treinamento da rede utilizando a tabela da liga 2024 sem nenhum tipo de modificação. O primeiro treinamento gerado apresentou um erro muito alto, o coeficiente de correlação r do treinamento ficou muito baixo da ordem de 0,55. O coeficiente r é a medida da capacidade da rede neural em entender o problema.

Foi feito então um primeira tentativa para que a rede entendesse melhor a tabela apresentada, essa primeira tentativa foi a triplicação dos dados da tabela, isto é, todas as entradas da tabela foram copiadas mais 2 vezes e essa nova tabela de dados (com dados triplicados) foi apresentada a rede.

Esse procedimento é muito comum em redes neurais e é usado para redes com poucos dados de entrada possibilitando a rede neural aprender melhor as relações entre os dados por repetição, como no aprendizado do ser humano que repete uma tarefa até entender e ter habilidade para dominar aquele aprendizado.

A triplicação dos dados fez com que a rede entendesse melhor os dados de entrada mas ainda apresentava erro muito alto e correlação R na faixa de 0,7.

Recorreu-se então a um segundo artifício de refino de dados. Foi feita uma normalização dos dados de entrada. Algumas vezes a rede neural pode se perder ao tentar entender dados cujas ordens de grandeza variam muito ou cujas ordens de grandeza sejam muito diferente entre as variáveis. Estudando os dados de entrada percebeu-se que essa variação era muito alta, estava-se trabalhando com dados de entrada de tempo na faixa de 6 minutos até 300.000 minutos, ou seja a variação da ordem de grandeza variava muito.

As seguintes normalizações foram utilizadas:

Para Limite de Escoamento:

$$\sigma_{\text{norm}} = \frac{\sigma - \sigma_{\min}}{\sigma_{\max} - \sigma_{\min}}$$

Para a Temperatura

$$T_{\text{norm}} = \frac{T - T_{\min}}{T_{\max} - T_{\min}}$$

Para a Tempo (Normalização Logarítmica)

$$t_{\text{norm}} = \frac{\log t - \log t_{\min}}{\log t_{\max} - \log t_{\min}}$$

Esta nova tabela, agora com dados normalizados foi apresentada a rede neural para treinamento e o resultado obtido foi muito satisfatório com correlação r de 0,99 para liga 2014 e 0,97 para liga 2024.

6.4.Capacidade de Generalização de uma Rede Neural

Coeficientes de correlação da ordem de 0,95 a 0,99 representam uma ótima capacidade da rede em entender o problema valores acima de 0,99 representam que a rede aprendeu as relações de entrada e saída com muita especificidade.

Valores muito altos de r não são desejados pois apesar do que se pode pensar a rede o r alto não quer dizer que o erro seja baixo, r alto significa que a rede aprendeu cada detalhe dos dados de entrada minuciosamente, inclusive os dados discrepantes, e por isso pode ter perdido sua capacidade de generalização.

A capacidade de generalização da rede neural é a capacidade da rede em apresentar resultados satisfatórios para dados que nunca foram apresentados a ela. Isto é, uma boa rede é aquela que consegue interpolar dados com grande eficiência e melhor ainda é a rede que consegue pela sua capacidade de generalização extrapolar o comportamento aprendido para valores fora do intervalo anteriormente apresentado a ela no treinamento.

6.5. Análise das Redes Neurais Criadas

A seguir serão apresentados os resultados das redes neurais para os dados de entrada triplicados e normalizados das ligas 2014 e 2024.

Liga 2014

Treinamento da rede para Liga 2014




Gráfico 5 . Aprendizado da rede para liga 2014

<i>Best Networks</i>	<i>Training</i>	<i>Cross Validation</i>
Epoch #	499	172
Minimum MSE	0,002144775	0,000689263
Final MSE	0,00258521	0,001038871

Tabela5 . Aprendizado da rede para liga 2014

Vemos que a rede aprendeu bem o comportamento e que o erro médio caiu a medida que as iterações ocorriam. (MSE – Medium Standard Error e Epoch – Iterações)

Desempenho da rede para Liga 2014




Gráfico 6. Desempenho da rede para liga 2014

<i>Performance</i>	<i>Resistência</i>
MSE	0,000788863
NMSE	0,01120862
MAE	0,022171926
Min Abs Error	0,000606069
Max Abs Error	0,073037461
r	0,994509043

Tabela 6 . Desempenho da rede para liga 2014

Podemos observar que o resultado esperado e o resultado que a rede forneceu ficaram bem próximos e que o r (coeficiente de correlação) ficou dentro da faixa ideal para que a rede apresente boa capacidade de generalização.

Análise de Sensibilidade para rede da Liga 2014




Grafico 7 .Análise de Sensibilidade liga 2014

<i>Sensitivity</i>	<i>Resistência</i>
Temperatura	0,1710573
Tempo	0,061666143




Grafico 8 .Análise de Sensibilidade da Temperautra Liga 2014




Grafico 9. Análise de Sensibilidade do Tempo Liga 2014

Observa-se que as duas variáveis tem comportamentos similares e que nas duas há picos de máximo. Esses picos significam que a Liga 2014 obtém um máximo de resistência mecânica nesses pontos de máximo nas duas variáveis.

Esse comportamento era esperado pois sabe-se que tanto para tempos e temperaturas pequenas de tratamento térmico pouco aumento da resistência mecânica é observada e, por outro lado, quando a temperatura é demasiadamente elevada e o tempo do tratamento térmico é muito longo ocorre o fenômeno de superenvelhecimento e a liga não tem suas propriedades mecânicas reduzidas.

Liga 2024

Treinamento da rede para Liga 2024




Gráfico 10 . Aprendizado da rede para liga 2024

<i>Best Networks</i>	<i>Training</i>	<i>Cross Validation</i>
Epoch #	499	172
Minimum MSE	0,002144775	0,000689263
Final MSE	0,00258521	0,001038871

Tabela7 . Aprendizado da rede para liga 2024

O treinamento da rede para liga 2024 também foi bem sucedido, vê-se que o erro médio diminuiu a medida que as iterações ocorriam. Alguma variação no aprendizado pode ser percebido com picos no aumento do erro médio, mas a rede foi suficientemente “esperta” para se ajustar e redirecionar o aprendizado na direção correta.

Desempenho da rede para Liga 2014




Gráfico 11. Desempenho da rede para liga 2024

<i>Performance</i>	<i>Escoamento</i>
MSE	0,00121125
NMSE	0,06231173
MAE	0,022516312
Min Abs Error	0,001185611
Max Abs Error	0,141236151
r	0,974068658

Tabela 8 . Desempenho da rede para liga 2024

Para a liga 2024 a rede neural também apresentou bons resultados de desempenho, obtendo um r e 0,97.

Análise de Sensibilidade para rede da Liga 2024




Grafico 12 .Análise de Sensibilidade liga 2024

<i>Sensitivity</i>	<i>Escoamento</i>
Temperatura	0,087752167
Tempo	0,106111237




Grafico 13 .Análise de Sensibilidade da Temperautra Liga 2024




Gráfico 14. Análise de Sensibilidade do Tempo Liga 2024

A análise de sensibilidade das variáveis mostra o mesmo comportamento esperado para tratamento térmico de ligas de Al-Cu observados na rede anterior da Liga 2014.

Vê-se que nos extremos a resistência mecânica é mínima e para valores intermediários obtém-se resistências mecânicas crescentes até atingir um máximo.

7. Recriação das Curvas de Envelhecimento pela Rede Neural

7.1 Produção dos Dados (Production)

As análises mostraram que as Redes Neurais para ambas as ligas tiveram muito sucesso em aprender o comportamento das curvas de envelhecimento. A Nova fase consiste em tentar recriar as curvas utilizando a Rede Neural para fornecer os valores de Tensão de Escoamento para valores de Tempo de Temperatura que cubram todo certo intervalo.

Os intervalos de tempo e temperatura escolhidos para liga foram:

Liga 2014

Tempo (Minutos)				Temperatura °C
6	440	850	1800	105
15	450	860	1900	110
30	460	870	2000	115
60	470	880	2100	120
70	480	890	2200	125
80	490	900	2300	130
90	500	910	2400	135
100	510	920	2500	140
110	520	930	2600	145
120	530	940	2700	150
130	540	950	2800	155
140	550	960	2900	160
150	560	970	3000	165
160	570	980	3100	170
170	580	990	3200	175
180	590	1000	3300	180
190	600	1010	3400	185
200	610	1020	3500	190
210	620	1030	3600	195
220	630	1040	3700	200
230	640	1050	3800	205
240	650	1060	3900	210
250	660	1070	4000	215
260	670	1080	4100	220
270	680	1090	4200	225
280	690	1100	4300	230
290	700	1110	4400	235
300	710	1120	4500	240
310	720	1130	4600	245
320	730	1140	4700	250
330	740	1150	4800	255
340	750	1160	4900	260
350	760	1170	5000	
360	770	1180	5100	
370	780	1190	5200	
380	790	1200	5300	
390	800	1300	5400	
400	810	1400	5500	
410	820	1500	5600	
420	830	1600	5700	
430	840	1700	5800	
			5900	
			6000	

Liga 2024

Tempo em Minutos			
60	470	880	2100
70	480	890	2200
80	490	900	2300
90	500	910	2400
100	510	920	2500
110	520	930	2600
120	530	940	2700
130	540	950	2800
140	550	960	2900
150	560	970	3000
160	570	980	3100
170	580	990	3200
180	590	1000	3300
190	600	1010	3400
200	610	1020	3500
210	620	1030	3600
220	630	1040	3700
230	640	1050	3800
240	650	1060	3900
250	660	1070	4000
260	670	1080	4100
270	680	1090	4200
280	690	1100	4300
290	700	1110	4400
300	710	1120	4500
310	720	1130	4600
320	730	1140	4700
330	740	1150	4800
340	750	1160	4900
350	760	1170	5000
360	770	1180	5100
370	780	1190	5200
380	790	1200	5300
390	800	1300	5400
400	810	1400	5500
410	820	1500	5600
420	830	1600	5700
430	840	1700	5800
440	850	1800	5900
450	860	1900	6000
460	870	2000	

Temperatura °C
100
105
110
115
120
125
130
135
140
145
150
155
160
165
170
175
180
185
190
195
200
205
210
215
220
225
230
235
240
245
250
255
260

As séries foram criadas da seguinte forma, para cada temperatura foi criada uma série com todos os valores de tempo em que se desejava obter o

valor da tensão de escoamento dado pela Rede Neural. Ou seja, a rede neural vai fornecer dados de tensão de escoamento que aprendeu anteriormente para cada uma das temperaturas de 105°C a 260°C, na faixa de tempo de 6 a 6.000 minutos para liga 2014 e de 100°C a 260°C, na faixa de tempo de 60 a 6.000 minutos.

Lembrando que ambas as redes aprenderam as relações utilizando os de entrada normalizados, as séries criadas para produção das curvas também foram normalizadas utilizando a mesma regra de normalização vista anteriormente.

Então com a série montada para cada liga e classificando-as como dados para produção no Neurosolutions (**Row as Production**) a rede neural realizou a produção de dados para cada série.

Os valores produzidos pela rede neural e posteriormente desnormalizados seguem no Anexo I.

7.2. Comparação das Curvas Produzidas Pela Rede Neural e Curvas da Literatura

A partir dos dados produzidos pela rede neural foram recriadas as curvas de envelhecimento para as duas ligas de estudo. Os resultados que a rede neural produziu nos pontos em que foram fornecidos como dados de entrada foram muito bons, a maioria dos pontos teve erro inferior a 10 %.

Abaixo temos as tabelas comparativas e os alguns gráficos comparando as curvas originais retirada do Metals Handbook e as curvas produzidas por redes neurais.

Análise dos Dados Fornecidos pelo Production X Dados Originais LIGA 2014

$$\text{Fórmula do Erro \%} = (\text{Resistência dada pelo Production RNA} - \text{Resistência Original retirada do Metals}) / \text{Resistência Original retirada do Metals}$$

Temperatura	105°C	Temperatura	135°C	Temperatura	150°C	Temperatura	175°C
Tempo Minutos	Erro %	Tempo Minutos	Erro %	Tempo Minutos	Erro %	Tempo Minutos	Erro %
60	-1,3%	60	5,8%	60	-7,1%	60	0,2%
120	-1,2%	120	5,7%	120	-4,9%	120	2,1%
240	-2,9%	240	4,2%	240	1,1%	240	-1,8%
360	-2,5%	360	5,7%	360	-7,2%	360	-1,3%
480	-2,1%	480	5,4%	480	-10,4%	480	-0,9%
600	-3,6%	600	7,7%	600	-10,1%	600	-0,8%
910	-2,6%	900	12,0%	900	-7,7%	900	0,2%
1500	-2,9%	1500	21,8%	1500	-4,3%	1500	0,3%
2400	-3,0%	2400	10,8%	2400	-2,6%	2400	2,2%
3900	-2,8%	3900	-1,7%	3900	-0,7%	3900	2,9%
6000	-1,1%	6000	3,3%	6000	-1,3%	6000	2,5%

Temperatura	190°C	Temperatura	205°C	Temperatura	230°C	Temperatura	260°C
Tempo Minutos	Erro %	Tempo Minutos	Erro %	Tempo Minutos	Erro %	Tempo Minutos	Erro %
6	-9,8%	6	0,8%	6	2,8%	6	-1,1%
15	12,9%	15	7,0%	15	-0,7%	15	-0,2%
60	10,8%	60	-0,6%	60	-0,2%	60	2,3%
120	2,2%	120	-4,3%	120	2,6%	120	1,4%
240	-2,7%	240	-3,3%	240	3,1%	240	-1,0%
360	-2,8%	360	-3,2%	360	1,3%	360	-2,2%
480	-2,9%	480	-2,8%	480	1,0%	480	-2,4%
600	-1,6%	600	-2,2%	600	2,0%	600	-3,8%
900	-3,3%	900	-4,1%	900	0,8%	900	-0,7%
1500	-3,4%	1500	-3,2%	1500	2,0%	1500	-0,6%
2400	-4,8%	2400	-1,3%	2400	0,9%	2400	2,4%
3900	-7,0%	3900	2,0%	3900	2,0%	3900	2,7%
6000	-9,1%	6000	3,9%	6000	4,0%	6000	4,6%

Erros maiores de 10 %

Tabela 9. Análise Comparativa de dados produzidos X originais 2014




Gráfico 15. Sobreposição de curvas a 135°C – Liga 2014




Gráfico 16. Sobreposição de curvas a 190°C – Liga 2014




Gráfico 17. Sobreposição de curvas a 205°C – Liga 2014

Análise dos Dados Fornecidos pelo Production X Dados Originais LIGA 2024

$$\text{Fórmula do Erro \%} = (\text{Resistência dada pelo Production RNA} - \text{Resistência Original retirada do Metals}) / \text{Resistência Original retirada do Metals}$$

Temperatura	100°C	Temperatura	130°C	Temperatura	150°C	Temperatura	160°C
Tempo Minutos	Erro %	Tempo Minutos	Erro %	Tempo Minutos	Erro %	Tempo Minutos	Erro %
60	1,6%	60	1,4%	60	2,1%	60	-2,1%
120	1,5%	120	1,2%	120	0,8%	120	-1,9%
240	1,4%	240	1,0%	240	1,2%	240	-2,8%
360	1,3%	360	0,8%	360	-0,1%	360	-1,9%
480	1,2%	480	0,7%	480	0,3%	480	-2,5%
600	1,1%	600	0,6%	600	-0,9%	600	-1,5%
900	0,9%	900	0,4%	900	-1,5%	900	-1,8%
1500	0,6%	1500	0,2%	1500	-1,0%	1500	0,5%
2400	0,3%	2400	0,1%	2400	-2,1%	2400	0,1%
3900	-0,1%	3900	0,3%	3900	-0,2%	3900	0,9%
6000	-0,6%	6000	1,0%	6000	-1,3%	6000	-0,1%

Temperatura	175°C	Temperatura	190°C	Temperatura	205°C	Temperatura	260°C
Tempo Minutos	Erro %	Tempo Minutos	Erro %	Tempo Minutos	Erro %	Tempo Minutos	Erro %
60	-2,2%	60	1,3%	60	6,5%	60	-5,8%
120	-0,6%	120	2,1%	120	0,1%	120	-5,4%
240	-1,4%	240	1,1%	240	0,9%	240	-4,2%
360	-2,0%	360	-1,9%	360	-1,9%	360	-4,1%
480	-2,6%	480	-5,6%	480	-5,1%	480	-4,2%
600	-0,8%	600	-6,3%	600	-8,1%	600	-3,4%
900	-1,1%	900	-1,6%	900	-12,1%	900	-4,7%
1500	-2,7%	1500	5,4%	1500	-12,1%	1500	-4,5%
2400	-0,7%	2400	3,6%	2400	-9,1%	2400	-6,8%
3900	1,5%	3900	1,9%	3900	-6,0%	3900	-3,4%
6000	-0,3%	6000	3,3%	6000	-5,2%	6000	-4,2%

Erros maiores de 10 %

Tabela 10. Análise Comparativa de dados produzidos X originais 2024




Gráfico 18. Sobreposição de curvas a 130°C – Liga 2024




Gráfico 19. Sobreposição de curvas a 190°C – Liga 2024




Gráfico 20. Sobreposição de curvas a 205°C – Liga 2024

7.3.Curvas de Envelhecimento Para as Temperaturas Não Fornecidas (interpolação de curvas)

Após verificar que o comportamento das curvas geradas pela Rede Neural nas temperaturas fornecidas para criação rede estava satisfatório (visto no item anterior), foi feita uma análise do comportamento das curvas para temperaturas intermediárias.

A dúvida era se a Rede Neural conseguiria criar curvas de envelhecimento coerentes para temperaturas não fornecidas.

O resultado foi muito positivo, as curvas criadas pela Rede Neural tiveram comportamento muito próximo do esperado. A seguir serão mostradas algumas curvas de envelhecimento para temperaturas intermediárias às fornecidas para treinamento da rede e também um gráfico em três dimensões que mostra todas as curvas de envelhecimento num mesmo gráfico de superfície.

LIGA 2014




Gráfico 21. Curvas de criadas por RNA de 105°C a 135 °C - liga 2014




Gráfico 22. Curvas de criadas por RNA de 140°C a 175 °C - liga 2014




Gráfico 23. Curvas de criadas por RNA de 180°C a 205 °C - liga 2014




Gráfico 24. Curvas de criadas por RNA de 210°C a 260 °C - liga 2014




Gráfico 25. Superfície criada por RNA (vista a 45°) - liga 2014




Gráfico 26. Superfície criada por RNA (vista a 90°) - liga 2014

LIGA 2024




Gráfico 27. Curvas de criadas por RNA de 100°C a 145 °C - Liga 2024




Gráfico 28. Curvas de criadas por RNA de 150°C a 170 °C - Liga 2024




Gráfico 29. Curvas de criadas por RNA de 175°C a 195 °C - Liga 2024




Gráfico 30. Curvas de criadas por RNA de 200°C a 250 °C - Liga 2024




Gráfico 31. Superfície criada por RNA (vista a 115°) - Liga 2024




Gráfico 32. Superfície criada por RNA (vista a 90°) - Liga 2024

8. Conclusões

Analisando as curvas de envelhecimento vê-se nitidamente que a Rede Neural foi capaz de aprender as relações entre Tempo e Temperatura de tratamento térmico com a Resistência Mecânica produzida por esse tratamento térmico.

Vê-se que o comportamento das curvas intermediárias, isto é, aquelas cujos dados não foram apresentados à rede, foi extremamente satisfatório nas duas ligas. Nota-se que os máximos de Tensão de Escoamento vai “caminhando” para a direita do gráfico (tempos mais curtos) à medida que a temperatura de tratamento térmico aumenta e que para valores muito altos esse máximo ocorre antes dos 60 minutos e a curva é uma curva decrescente que está de acordo com o fenômeno de superenvelhecimento da liga que a fragiliza.

Alguma discrepância foi observada na liga 2024 para tratamentos térmicos em temperaturas na faixa de 210 a 250 graus, essas curvas mostraram um comportamento atípico para a faixa de temperaturas indicando máximos secundários de Tensão de Escoamento. Nessas faixas de Temperatura para tempos acima dos 60 minutos (mínimo da escala estudada) a Tensão de Escoamento só tende a decrescer devido à ocorrência do fenômeno de superenvelhecimento da liga.

De qualquer forma, no geral, a Rede Neural forneceu dados condizentes com o comportamento que se esperava para o tratamento térmico das duas ligas estudadas e pode ser aplicada para processar problemas de Tratamento Térmico de ligas Al-Cu.

Os dados fornecidos no Anexo I deste trabalho podem servir como base para estimar a Tensão de Escoamento de Ligas 2014 e 2024 nos respectivos tratamentos térmicos.

9.Sugestões Para Trabalhos Futuros

Para trabalhos futuros seguindo a mesma linha proponho utilizar como dado de entrada da rede neural dados de composição da liga.

A nova Rede Neural terá o trabalho de aprender além da relação de temperatura X tempo e seu efeito na Tensão de Escoamento mas também o efeito dos elementos de liga e suas porcentagens na Tensão de Escoamento

Este trabalho poderá fornecer uma rede para definir com exatidão qual o tratamento térmico que fornece o melhor desempenho em termos de resistência e custo para a composição da liga que se deseja tratar termicamente.

ANEXO I

		Temperature (°C)																																
		100	110	115	120	125	130	135	140	145	150	155	160	165	170	175	180	185	190	195	200	205	210	215	220	225	230	235	240	245	250	255	260	
6	242.5	241.7	240.7	239.7	238.8	237.7	235.5	234.7	233.7	231.7	229.8	226.9	224.2	221.3	218.3	215.1	211.3	205.7	195.7	193.8	213.5	257.1	309.2	347.6	367.3	374.7	375.3	370.0	366.3	359.3	350.9	341.5	331.1	315.1
15	242.1	241.2	240.2	239.0	237.7	236.2	234.4	232.5	230.4	228.0	225.5	223.2	221.1	220.0	215.2	206.2	204.8	200.0	182.1	175.5	348.1	325.5	358.4	375.2	381.3	377.9	372.7	364.9	356.4	346.1	334.9	322.6	309.8	291.5
30	241.9	240.9	239.8	238.5	237.0	235.4	233.6	231.5	229.1	227.2	225.2	224.2	222.5	220.0	215.7	206.7	205.8	200.0	182.5	175.7	347.8	325.1	358.1	375.5	381.7	378.5	371.9	363.6	353.7	342.4	329.7	315.5	302.0	283.5
45	241.8	240.7	239.5	238.0	236.5	234.7	232.7	230.7	228.3	226.1	223.9	221.5	219.1	216.4	210.0	200.0	194.2	188.0	182.8	176.7	347.9	325.2	358.2	375.6	381.8	378.6	371.9	363.6	353.7	342.4	329.7	315.5	302.0	283.5
60	241.8	240.7	239.4	238.0	236.3	234.5	232.6	230.7	228.2	225.9	223.4	221.0	218.4	215.7	210.0	200.0	194.2	188.0	182.8	176.7	347.9	325.2	358.2	375.6	381.8	378.6	371.9	363.6	353.7	342.4	329.7	315.5	302.0	283.5
75	241.8	240.7	239.4	238.0	236.3	234.5	232.6	230.7	228.2	225.9	223.4	221.0	218.4	215.7	210.0	200.0	194.2	188.0	182.8	176.7	347.9	325.2	358.2	375.6	381.8	378.6	371.9	363.6	353.7	342.4	329.7	315.5	302.0	283.5
90	241.8	240.7	239.4	238.0	236.3	234.5	232.6	230.7	228.2	225.9	223.4	221.0	218.4	215.7	210.0	200.0	194.2	188.0	182.8	176.7	347.9	325.2	358.2	375.6	381.8	378.6	371.9	363.6	353.7	342.4	329.7	315.5	302.0	283.5
105	241.8	240.7	239.4	238.0	236.3	234.5	232.6	230.7	228.2	225.9	223.4	221.0	218.4	215.7	210.0	200.0	194.2	188.0	182.8	176.7	347.9	325.2	358.2	375.6	381.8	378.6	371.9	363.6	353.7	342.4	329.7	315.5	302.0	283.5
120	241.8	240.7	239.4	238.0	236.3	234.5	232.6	230.7	228.2	225.9	223.4	221.0	218.4	215.7	210.0	200.0	194.2	188.0	182.8	176.7	347.9	325.2	358.2	375.6	381.8	378.6	371.9	363.6	353.7	342.4	329.7	315.5	302.0	283.5
135	241.8	240.7	239.4	238.0	236.3	234.5	232.6	230.7	228.2	225.9	223.4	221.0	218.4	215.7	210.0	200.0	194.2	188.0	182.8	176.7	347.9	325.2	358.2	375.6	381.8	378.6	371.9	363.6	353.7	342.4	329.7	315.5	302.0	283.5
150	241.8	240.7	239.4	238.0	236.3	234.5	232.6	230.7	228.2	225.9	223.4	221.0	218.4	215.7	210.0	200.0	194.2	188.0	182.8	176.7	347.9	325.2	358.2	375.6	381.8	378.6	371.9	363.6	35					

THE
N
P
C
E
M
H
I
R

1

Downloaded from <http://ajphaphysocpharm.sagepub.com/> at 11:06 11 November 2014

Valores de Resistência Mecânica Produzidos pela Rede Neural LIGA 2024 - Continuação

		Temperatura °C																																	
		100	105	110	115	120	125	130	135	140	145	150	155	160	165	170	175	180	185	190	195	200	205	210	215	220	225	230	235	240	245	250	255	260	
	1170	347,7	347,3	346,9	346,5	346,2	346,0	346,0	346,2	346,6	346,6	346,1	342,9	338,4	341,9	357,1	380,3	405,8	425,7	433,7	425,4	398,6	367,4	353,1	355,2	362,7	369,0	371,9	371,1	366,1	355,7	337,8	310,8	276,8	242,7
	1180	347,7	347,3	346,9	346,5	346,2	346,0	346,0	346,2	346,6	346,6	346,2	343,0	338,6	342,2	357,5	380,8	406,3	426,0	433,7	425,1	397,9	366,8	353,0	355,2	362,8	369,0	371,9	371,0	365,9	355,4	337,4	310,4	276,3	242,2
	1190	347,7	347,3	346,9	346,5	346,2	346,0	346,0	346,2	346,6	346,6	346,2	343,1	338,8	342,5	357,9	381,3	406,7	426,2	433,7	424,7	397,2	366,3	352,9	355,3	362,8	369,0	371,9	370,9	365,8	355,3	337,1	309,9	275,8	241,8
	1200	347,6	347,3	346,9	346,5	346,2	346,0	346,0	346,2	346,6	346,6	346,3	343,2	339,0	342,8	358,3	381,8	407,2	426,5	433,7	424,3	396,6	365,8	352,8	355,4	362,9	369,1	371,8	370,8	365,6	354,9	336,7	309,5	275,3	241,3
	1300	347,5	347,1	346,7	346,3	346,0	345,8	345,9	346,2	346,8	346,8	346,8	344,3	340,9	345,8	362,4	386,6	411,4	428,9	433,3	420,3	390,0	361,4	351,9	356,2	363,7	369,3	371,4	369,7	363,8	352,4	333,3	305,1	270,5	236,9
	1400	347,3	346,9	346,5	346,1	345,8	345,7	345,8	346,2	347,0	347,4	345,4	342,9	348,7	366,4	391,1	415,1	430,6	432,3	415,8	383,7	357,9	351,5	356,9	364,3	369,3	370,8	368,6	362,1	350,0	330,0	301,0	266,1	232,8	
	1500	347,2	346,8	346,3	346,0	345,7	345,5	345,7	346,3	347,3	347,9	346,6	344,8	351,6	370,2	395,2	418,3	431,9	430,9	411,2	378,3	355,3	351,5	357,6	364,8	369,2	370,2	367,5	360,4	347,6	326,8	297,1	261,9	229,1	
	1600	347,0	346,6	346,2	345,8	345,5	345,4	345,6	346,3	347,5	348,5	347,7	346,8	354,5	373,9	399,0	421,1	432,7	429,1	406,5	373,4	353,2	351,6	358,3	365,1	369,1	369,5	366,3	358,7	345,3	323,7	293,3	258,0	225,7	
	1700	346,9	346,5	346,0	345,6	345,4	345,3	345,6	346,4	347,8	349,1	348,9	348,7	357,3	377,4	402,5	423,4	433,2	427,0	401,7	369,0	351,7	351,9	358,9	365,4	368,9	368,8	365,2	357,1	343,0	320,8	289,8	254,4	222,5	
	1800	346,8	346,3	345,9	345,5	345,4	345,2	345,5	346,4	348,0	349,8	350,1	350,6	360,1	380,8	405,7	425,5	433,3	424,6	397,1	365,2	350,5	352,2	359,4	365,6	368,6	368,1	364,0	355,5	340,8	317,9	286,4	251,0	219,5	
	1900	346,6	346,2	345,7	345,4	345,1	345,1	345,5	346,5	348,3	350,4	351,3	352,5	362,8	384,0	408,6	427,2	433,2	422,0	392,5	361,9	349,7	352,6	359,9	365,7	368,2	367,4	362,9	353,9	338,7	315,1	283,1	247,7	216,7	
	2000	346,5	346,0	345,6	345,2	345,0	345,0	345,5	346,6	348,6	351,0	352,4	354,4	365,4	387,1	411,3	428,5	432,8	419,2	388,2	359,0	349,1	353,0	360,3	365,7	367,9	366,6	361,7	352,3	336,6	312,5	280,0	244,7	214,1	
	2100	346,4	345,9	345,5	345,1	344,9	344,9	345,4	346,7	348,9	351,7	353,6	356,3	368,0	390,0	413,7	429,8	432,1	416,3	384,0	356,6	348,8	353,4	360,6	365,7	367,5	365,8	360,6	350,8	334,6	309,9	277,1	241,8	211,6	
	2200	346,3	345,8	345,3	345,0	344,7	344,8	345,4	346,8	349,2	352,3	354,8	358,2	370,5	392,8	416,0	430,7	431,3	413,3	380,1	354,5	348,5	353,8	360,9	365,6	367,0	365,1	359,5	349,3	323,6	307,4	274,2	239,0	209,3	
	2300	346,2	345,7	345,2	344,8	344,6	344,8	345,4	347,0	349,6	353,0	356,0	360,0	373,0	395,4	418,0	431,5	430,3	410,1	376,5	352,7	348,4	354,2	361,1	365,5	366,6	364,3	358,4	347,9	330,7	304,9	271,5	236,4	207,2	
	2400	346,0	345,5	345,1	344,7	344,5	344,7	345,4	347,1	349,9	353,7	357,2	361,9	375,4	397,9	419,9	432,1	429,1	407,0	373,1	351,2	348,4	354,6	361,3	365,3	366,1	363,5	357,3	346,4	328,8	302,6	268,8	233,9	205,1	
	2500	345,9	345,4	345,0	344,6	344,4	344,6	345,4	347,2	350,3	354,4	358,4	363,7	377,7	400,3	421,5	432,5	427,8	403,8	369,9	350,0	348,5	354,9	361,5	365,2	365,6	362,7	356,3	345,3	326,9	300,3	266,3	231,5	203,1	
	2600	345,8	345,3	344,9	344,5	344,3	344,6	345,5	347,4	350,6	355,0	359,5	365,5	380,0	402,6	423,1	432,7	426,4	400,6	367,0	348,9	348,6	355,3	361,6	365,0	365,1	362,0	355,2	343,6	325,1	298,0	263,9	229,3	201,3	
T	2700	345,7	345,2	344,8	344,4	344,3	344,5	345,5	347,5	351,0	355,7	360,7	367,2	382,2	404,7	424,4	432,8	424,8	397,4	364,4	348,1	348,7	355,5	361,6	364,7	364,6	361,2	354,2	342,2	323,4	295,9	261,5	227,1	199,5	
e	2800	345,6	345,1	344,6	344,3	344,2	344,5	345,5	347,7	351,3	356,4	361,9	368,9	384,3	406,7	425,6	432,8	423,1	394,3	361,9	347,3	348,9	355,8	361,7	364,5	364,1	360,4	353,1	340,9	321,6	293,8	259,2	225,0	197,9	
m	2900	345,5	345,0	344,5	344,2	344,1	344,4	345,5	347,8	351,7	357,1	363,0	370,7	386,4	408,6	426,7	432,7	421,4	391,3	359,7	346,7	349,1	356,0	361,7	364,2	363,5	359,7	352,1	339,6	320,0	291,7	257,1	223,0	196,3	
p	3000	345,4	344,9	344,4	344,1	344,0	344,4	345,6	348,0	352,1	357,8	364,2	372,3	388,4	410,4	427,7	432,4	419,5	388,3	357,7	346,0	349,3	356,3	361,6	363,9	363,0	358,9	351,3	338,3	318,3	289,7	254,9	221,1	194,7	
o	3100	345,3	344,8	344,3	344,0	343,9	344,4	345,6	348,2	352,5	358,5	365,4	374,0	390,4	412,1	428,6	432,1	417,6	385,4	355,9	345,9	349,5	356,4	361,6	363,6	362,5	358,1	350,1	337,0	316,7	287,8	252,9	219,3	193,3	
o	3200	345,2	344,7	344,2	343,9	343,9	344,3	345,7	348,4	352,9	359,2	366,5	375,6	392,2	413,7	429,3	431,7	415,6	382,7	354,2	345,6	349,7	356,6	361,5	363,3	361,9	357,4	349,2	335,8	315,1	285,9	250,9	217,6	191,9	
e	3300	345,1	344,6	344,1	343,8	343,8	344,3	345,7	348,5	353,3	360,0	367,7	377,2	394,1	415,2	430,0	431,1	413,6	380,0	352,7	345,3	349,9	356,7	361,4	363,0	361,4	356,7	348,2	334,5	313,5	284,0	249,0	215,9	190,5	
m	3400	345,0	344,5	344,0	343,7	343,7	344,3	345,8	348,7	353,7	360,7	368,8	378,8	395,8	416,6	430,5	430,5	411,5	377,4	351,4	345,1	350,1	356,9	361,3	362,6	360,8	355,9	347,2	333,3	312,0	282,2	247,2	214,2	189,3	
3500	344,9	344,4	343,9	343,6	343,7	344,3	345,9	348,9	354,1	361,4	369,9	380,4	397,5	418,9	431,0	429,8	409,4	374,9	350,4	345,0	350,3	357,0	361,2	362,3	360,3	355,2	346,3	332,1	310,3	280,5	245,2	212,7	188,0		
M	3600	344,8	344,3	343,8	343,6	343,6	344,3	345,9	349,1	354,5	362,1	371,0	381,9	399,2	419,1	431,4	429,1	407,3	372,6	349,0	344,9	350,5	357,0	361,1	361,9	359,8	354,5	345,4	330,9	309,0	278,8	243,6	211,2	186,8	
i	3700	344,8	344,2	343,8	343,5	343,6	344,3	346,0	349,3	354,9	362,8	372,1	383,4	400,7	420,3	431,7	428,2	405,1	370,4	348,1	344,9	350,7	357,1	360,9	361,6	359,2	353,8	344,5	329,8	307,6	277,1	241,9	209,7	185,7	
n	3800	344,7	344,1	343,7	343,4	343,5	344,2	346,1	349,5	355,3	363,5	373,2	384,8	402,3	421,4	432,0	427,4	403,0	368,2	347,2	344,9	350,9	357,2	360,8	361,2	358,7	353,1	343,6	328,7	306,2	275,5	240,3	208,3	184,6	
u	3900	344,6	344,0	343,6	343,3	343,5	344,2	346,1	349,7	355,7	364,2	374,3	386,3	403,7	422,4	432,2	426,4	400,9	366,2	346,4	344,9	351,0	357,2	360,6	360,9	358,2	352,4	342,7	327,5	304,8	273,9	238,7	207,0	183,5	
t	4000	344,5																																	

Referências

1. Dobrzanski, L. A.; Tanski, T.; Trzaskas J.; Optimization of heat treatment conditions of magnesium cast alloys; Polônia
2. Song, R.G.; Zang, Q. Z.; Heat Treatment optimization for 7175 aluminum alloy by genetic algorithm; Materials Science Engineering C17 (2001) 133-137
3. Carlini, R. C.; Aplicações de Redes Neurais Adaptativas na Previsão das Curvas Tensão Deformação de Aços; São Paulo, 2008
4. Bocabello, R. Z.; Desenvolvimento de uma rede neural artificial para parametrização de forno de tratamento térmico de solubilização para liga AlCuSiSn; São Paulo, 2008
5. Cossa, D. de A.; Emprego de RNA para aços microligados ensaiados em dilatômetro Bähr visando obtenção de macro HV e Ar3; São Paulo, 2010.
6. Kong, L. X.; Hodgson, D. C.; Collinson, D. C.; Extrapolative prediction of the hot strength of austenitic steels with a combined constitutive and ANN model; Journals of Materials Processing Technology 102 (2000) 84 - 89
7. ASM Handbook Vol 4. ASM International, Cap. Heat Treating of Aluminum Alloys, 2002
8. ASM Handbook Vol 2. ASM International, Caps. Introduction to Aluminum and Aluminum Alloys, Aluminum Mill And Engineered Wrought Products, Properties of Wrought Aluminum and Aluminum Alloys, 2002
9. ASM Handbook Vol 9. ASM International, Caps. Structure by Precipitation From Solid Solution, 2002
10. Handbook of Aluminum V.1, cap 5, 2003