

5 Reconhecimento de Padrões

Neste trabalho, a interface cérebro máquina é baseada no condicionamento operante. Sendo assim, quatro atividades mentais distintas e comprovadamente relacionadas a alterações do RSM foram utilizadas. São elas: movimento imaginário do braço esquerdo, braço direito, língua, e pés. Essas atividades foram respectivamente chamadas de LM (*Left Movement*), RM (*Right Movement*), UM (*Up Movement*) e DM (*Down Movement*), de acordo com as funções a que são associadas durante a aplicação da interface.

A fim de se classificar as atividades mentais, classificadores baseados em Redes Neurais foram propostos e utilizados. Todos os modelos foram treinados e avaliados com as mesmas bases de dados. A topologia de cada rede foi obtida através de uma rotina de avaliação do resultado quando variados o número de processadores na camada escondida, momentum e taxa de aprendizado. Durante a rotina, a mesma base de dados é utilizada para treinar e avaliar o resultado de diferentes topologias. O número de processadores na camada escondida foi variado de 5 a 60, o termo de momentum de 0 a 1 com passo de 0,1, e a taxa de aprendizado de 0,2 a 1 com passo de 0,01. Cada topologia passou pela fase de treinamento e teste apenas uma vez. Ao final da rotina, uma tabela com os resultados foi gerada, e a topologia escolhida foi a que apresentou melhor resultado. Para evitar que a escolha fosse feita como um caso isolado, os resultados das redes com topologia semelhante também foram observados se mostraram quase tão bons quanto a escolhida, destacando-se das outras topologias.

A base de dados é composta por 400 padrões de treinamento, 200 padrões de validação e 200 padrões de testes, sendo cada um desses três grupos (treinamento, validação e testes) dividido igualmente entre as quatro atividades mentais a serem identificadas. A avaliação do desempenho dos modelos propostos foi obtida pelo resultado médio de dez bases de dados geradas pelo mesmo usuário.

5.1. Comitê de Redes Neurais MLP com DPR

O primeiro modelo proposto para esse problema é um comitê de redes neurais *Multi Layer Perceptron* (MLP), devido ao seu bom desempenho na generalização [64]. O comitê é composto por quatro redes MLP, e cada uma delas classifica melhor um dos quatro grupos (RM, LM, UM e DM) (Figura 35).

A replicação direcionada de padrões (*Driven Pattern Replication – DPR*) é utilizada para criar diferentes membros do comitê. Cada membro especializado na classificação de um dos quatro grupos é treinado com os padrões correspondentes a esse grupo replicados quatro vezes no conjunto de treinamento, enquanto o número de padrões respectivos às outras atividades mentais se mantém o mesmo.

Cada membro é então treinado com seu respectivo conjunto de treinamento, e no treinamento de todos eles é utilizada a parada antecipada, permitindo-se que o erro do conjunto de validação cresça por 80 épocas de treinamento. Cada rede é composta por 24 processadores na camada de entrada, 32 na camada escondida e 4 na camada de saída (um para cada atividade mental). Durante o treinamento foi utilizado um termo de “momentum” igual a 0,7 e taxa de aprendizagem adaptativa igual a 0,75.

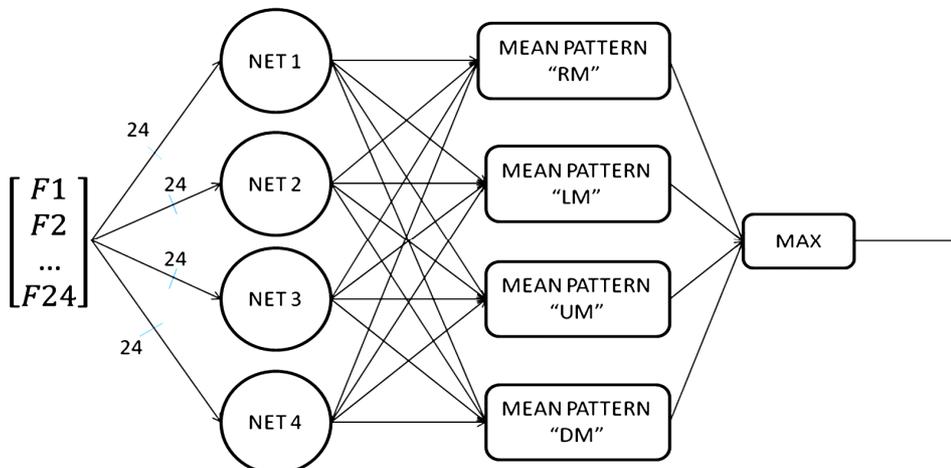


Figura 35 - Comitê de redes MLP com DPR.

A obtenção do resultado do classificador é feita apresentando-se um vetor característico aos quatro membros do comitê e, em seguida, combinando-se as saídas correspondentes a uma mesma atividade mental pelo seu valor médio. O grupo (atividade mental) que possuir a maior média de classificação é então escolhido como o que representa o padrão apresentado.

5.2. Múltiplas Redes Modulares (MRM).

Nesse modelo (Figura 36), outra vez, quatro redes neurais são usadas. Porém, dessa vez, cada rede possui apenas duas saídas, e é treinada para classificar o vetor apresentado como pertencendo ou não ao grupo para o qual foi treinada para classificar.

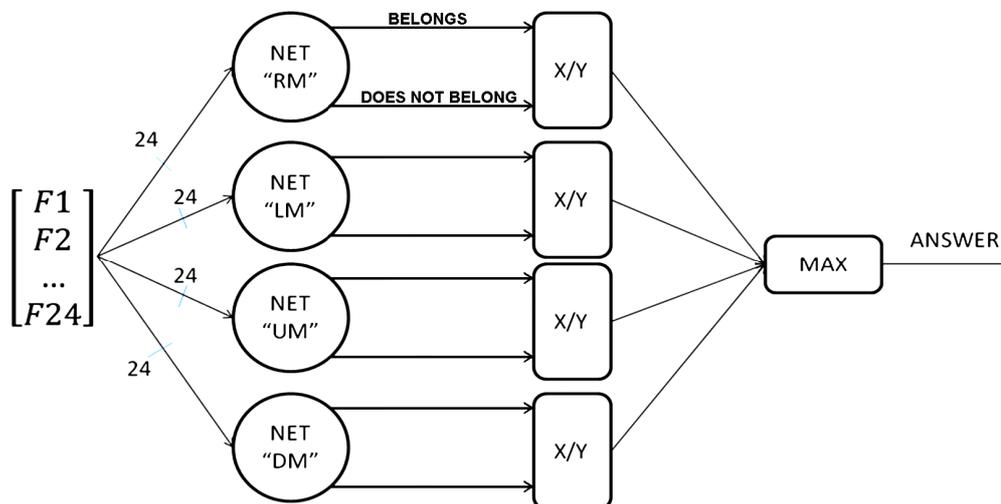


Figura 36 - Classificador baseado em múltiplas redes modulares.

A combinação das respostas das redes é feita em duas etapas. Primeiramente é atribuído um grau de certeza da classificação de cada rede. Isso é feito dividindo-se o valor da saída relativa ao grupo "pertence ao grupo" pelo valor da saída "não pertence ao grupo". Em seguida, é aplicada uma operação de máximo entre os quatro graus obtidos para identificar o grupo classificado.

Um modelo combinando diretamente cada saída "pertence ao grupo" pelo operador "máximo" também foi testada. Entretanto, a atribuição do grau pela divisão das duas saídas de cada rede resultou em uma melhor taxa de acerto na classificação.

Cada rede é treinada com o mesmo conjunto de treinamento, validação e testes, contendo todos os padrões de cada um dos quatro grupos (atividades mentais). A diferenciação é feita alterando-se apenas os "targets" de treinamento. Sendo assim, cada rede passa a possuir, no conjunto de treinamento, 300 padrões a serem treinados como "não pertence ao grupo", e apenas 100 padrões com "targets" de "pertence ao grupo". Isso poderia causar uma tendência da rede em classificar grande parte dos padrões apresentados como não pertencentes ao grupo. Para evitar isso, os padrões do conjunto de treinamento relativos ao grupo "pertence ao grupo" foram replicados três vezes,

igualando assim o número de padrões de cada grupo no conjunto de treinamento.

No treinamento das quatro redes é utilizada a parada antecipada, permitindo-se que o erro do conjunto de validação cresça por 80 épocas de treinamento. Cada rede é composta por 24 processadores na camada de entrada, 28 na camada escondida, e 2 na camada de saída (“pertence ao grupo” e “não pertence ao grupo”). Durante o treinamento, foi utilizado um termo de “momentum” igual a 0,8 e taxa de aprendizagem adaptativa igual a 0,75.

5.3. Modelo Hierárquico (MH).

O modelo hierárquico foi proposto após avaliar o desempenho do modelo MRM. Analisando a matriz de confusão (Tabela 2) do modelo citado, é possível observar que a maioria dos padrões classificados de maneira errada está entre os grupos “UM” e “DM”.

Tabela 2 - Matriz de confusão do modelo MRM.

	DM	UM	RM	LM
DM	27	13	4	6
UM	10	22	9	9
RM	2	2	40	6
LM	6	6	11	27

Sendo assim, o modelo hierárquico é dividido em dois níveis, como pode ser visto na Figura 37. No primeiro nível, redes neurais MLP são utilizadas como no modelo MRM, distinguindo o padrão apresentado como pertencendo ou não ao seu grupo. Entretanto, ao invés de quatro grupos, o primeiro nível distingue apenas entre três grupos: RM, DM e um novo padrão resultante da união dos dois restantes {DM ou UM}. No segundo nível, caso o grupo {DM ou UM} tenha sido pré-classificado no primeiro nível, uma nova rede MLP é utilizada para classificar entre os padrões DM e LM.

Sendo assim, o mesmo vetor característico é apresentado a todas as redes do primeiro e segundo níveis. A classificação final depende dos classificadores do primeiro nível do modelo. Se a rede treinada para reconhecer o grupo {DM ou UM} apresentar a maior saída (grau calculado como no modelo MRM) entre as três do primeiro nível, então a resposta do sistema é dada pela

classificação do segundo nível do modelo. Caso contrário, a resposta é obtida pela rede do primeiro nível com maior valor de saída.

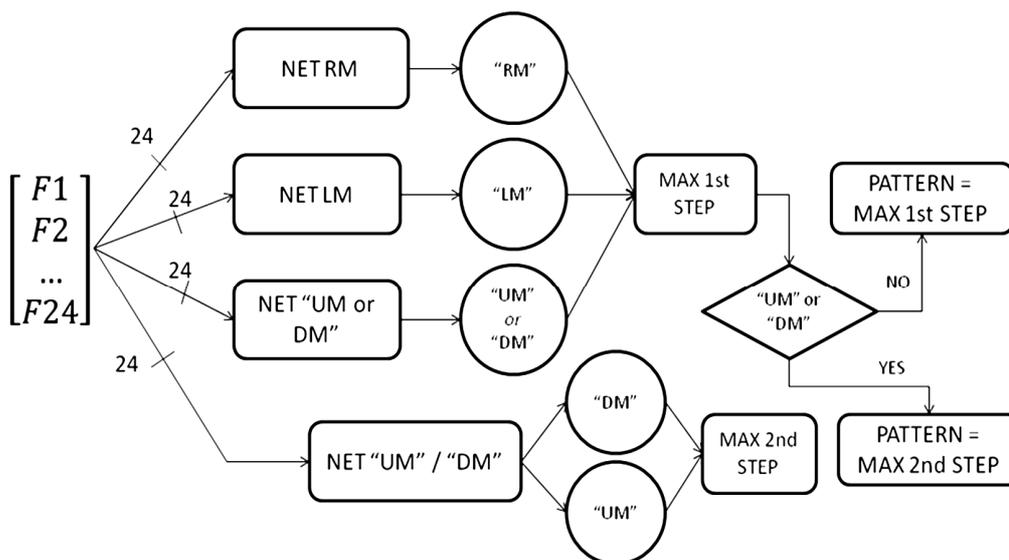


Figura 37 - Modelo Hierárquico.

Como resultado, a nova matriz de confusão apresenta melhores resultados que o modelo MRM, aumentando as classificações corretas não só dos padrões antes confusos, como também do padrão LM.

Tabela 3 - Matriz de confusão do modelo hierárquico.

	DM	UM	RM	LM
DM	28	12	4	6
UM	5	27	9	9
RM	2	2	40	6
LM	6	5	9	30

Como pode ser visto na Tabela 4, o modelo hierárquico resultou num aumento considerável da taxa de acerto em relação aos outros classificadores. Para fins comparativos, um modelo de classificador com uma única rede MLP e outro modelo baseado em redes neurais proposto por Achanccaray² [65] (com o respectivo processo de extração de características) foram avaliados.

² Achanccaray analisou as variações da Banda Delta durante a imaginação do movimento e outras atividades cognitivas, e utilizou redes neurais probabilísticas para classificar os padrões.

Como mencionado anteriormente, o resultado foi obtido pela média dos resultados de 10 conjuntos de testes, cada um contendo 200 padrões (50 padrões de cada atividade mental), gravados de um mesmo usuário. Os resultados apresentados foram avaliados com e sem a remoção de artefatos oculares do conjunto de padrões de treinamento, e é possível verificar que a remoção dos mesmos não resultou numa melhora significativa na taxa de acerto dos classificadores.

Tabela 4 - Taxas de acerto dos diferentes classificadores.

	Com remoção de artefatos	Sem remoção de artefatos
Achancaray (2009)	36%	36%
MLP	54%	54%
Comitê	60%	59%
MRM	61%	59%
HM	65%	63%

Os modelos propostos resultaram em taxas de acerto entre 60% e 65%. Entretanto, essas taxas de acerto ainda podem ser insuficientes para algumas das tarefas de uma interface cérebro máquina. Dessa forma, não é uma boa idéia usar uma única tentativa (padrão) para ser classificado e convertido em uma ação da BMI durante a aplicação.

Para resolver esse problema, duas implementações dos modelos de classificação propostos foram feitas, utilizando múltiplas tentativas. Estas implementações tornam, inclusive, desnecessária a remoção de artefatos. As duas implementações usam consecutivas tentativas de 1 segundo de leitura do EEG cada, que são processadas, classificadas individualmente, e então combinadas para resultar numa classificação final do sistema, como é descrito a seguir.

5.4.Implementação de Disparo com MRM.

Nessa primeira implementação, o modelo de Múltiplas Redes Modulares (MRM) foi utilizado para classificar cada tentativa pois, além de ter apresentado uma taxa de acertos similar ao comitê de redes neurais, fornece um grau de classificação atribuído a cada um dos grupos estimados da mesma maneira (o modelo hierárquico utiliza redes diferentes devido à sua divisão em dois níveis). Os graus atribuídos para cada saída (correspondentes aos quatro grupos RM,

LM, UM e DM) são somados aos graus correspondentes da próxima tentativa / classificação até que um valor de disparo seja alcançado por um dos quatro grupos, quando é então declarado como o grupo desejado. No exemplo do esquema da Figura 38, a atividade mental do usuário corresponde ao padrão UM e o valor de disparo igual a 5 e, mesmo com uma tentativa classificada errada (tentativa 2), o sistema consegue distinguir a atividade desejada quando, neste exemplo, o somatório atinge o valor 5.2 (maior ou igual a 5).

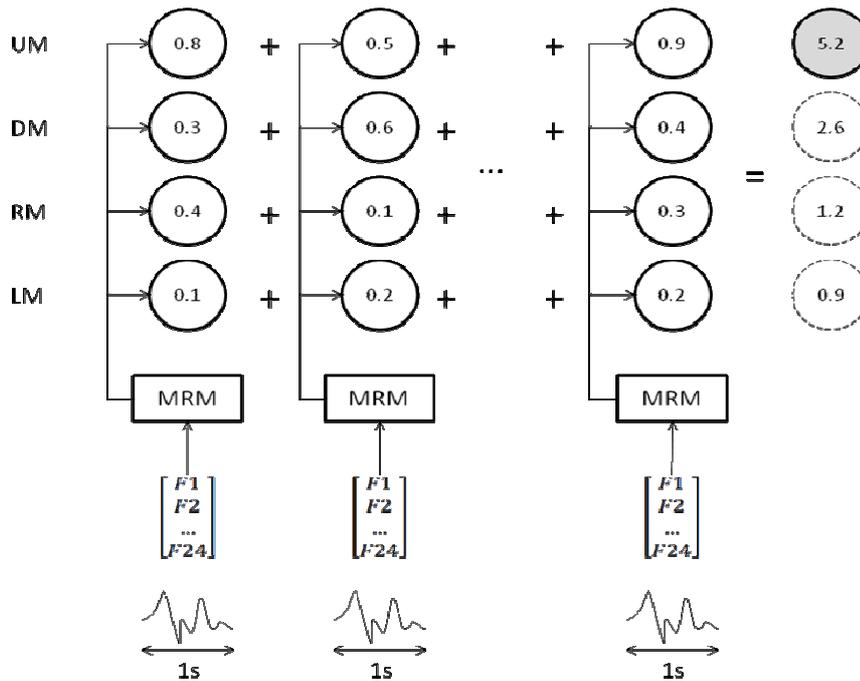


Figura 38 - Exemplo de implementação de disparo com MRM.

É evidente que quanto maior o número de tentativas, maior é a probabilidade de uma classificação final correta, pois a probabilidade de acerto do grupo desejado (o que resulta em graus atribuídos maiores para aquele grupo) em cada tentativa é de 60% (probabilidade obtida com os classificadores), enquanto a probabilidade dos outros grupos está dividida nos 40% restantes. Dessa forma, espera-se que a diferença do somatório dos graus de cada grupo aumente ao longo das tentativas.

O valor de disparo é escolhido, então, de acordo com a habilidade do usuário em se concentrar na atividade mental desejada. Quanto maior a capacidade de concentração do usuário, mais rápido o somatório dos graus da atividade mental desejada diverge dos outros e, conseqüentemente, o número de tentativas pode ser menor, bem como o valor de disparo. Dessa forma, na primeira vez em que o usuário utiliza o sistema, é natural que um valor de

disparo alto seja escolhido e, na medida em que o usuário ganhe experiência em gerar os padrões corretos, esse valor pode ser reduzido.

É importante ressaltar que o grau atribuído pelas redes para cada grupo é limitado ao valor três, pois caso a saída “não pertence ao grupo” tenda a zero, o grau resultante da divisão das duas saídas tenderia a infinito. Então, numa classificação nas melhores condições possíveis, o grau atribuído seria três. Nesse trabalho, o menor valor de disparo atribuído foi 5, o que requer pelo menos duas tentativas de controle. Caso o número de tentativas exceda quinze vezes, determinou-se que nenhuma divergência significativa ocorreu entre o somatório de cada grupo, e o comando é então declarado como “confuso” e nenhuma ação da BMI é tomada.

Deve-se considerar também a possibilidade de dois grupos atingirem o valor de disparo na mesma tentativa. Nesse trabalho, essa situação resulta na ausência de comandos da interface, classificando o comando como “confuso”. Entretanto, essa possibilidade abre espaço para o estudo de uma possível combinação entre os quatro grupos. Por exemplo, caso os grupos UM (associado ao movimento para cima) e RM (associado ao movimento para direita) atingissem o valor de disparo numa mesma tentativa, uma ação intermediária entre esses dois grupos, como mover-se na diagonal superior direita, poderia ser executada pela BMI.

5.5.Implementação Estatística com o Modelo Hierárquico

Como na implementação por disparo, a implementação estatística foi criada de forma a precisar de mais de uma tentativa para dar uma resposta de classificação. Entretanto, ao invés do modelo MRM, o modelo hierárquico é usado como classificador em cada tentativa.

Nessa implementação, a ocorrência da classificação de cada grupo em “n” tentativas é avaliada após um número mínimo de tentativas N_{\min} . Após o número mínimo de tentativas, novas tentativas são avaliadas até que a ocorrência da classificação de um grupo seja maior ou igual a 50%, quando esse grupo é então escolhido como resposta final. Na Figura 39, um exemplo de classificação é apresentado. Após o mínimo de 5 tentativas, somente na oitava tentativa o grupo UM apresentou uma ocorrência maior ou igual a 50%, quando foi então declarado como a classificação final do sistema.

Caso o número de tentativas exceda 15, o comando é declarado como “confuso”, e nenhum comando da BMI é executado. Assim como na implementação por disparo, o número mínimo de tentativas pode aumentar ou

diminuir conforme a habilidade do usuário em gerar os padrões corretos, bem como a porcentagem de ocorrência de classificações de um grupo em “n” tentativas. Vale lembrar que a probabilidade natural de ocorrência entre quatro grupos é de 25%, logo, para se fazer uma classificação, é necessário que o índice de ocorrência seja maior que 25%. Uma análise computacional detalhada deste modelo é feita no capítulo 6.

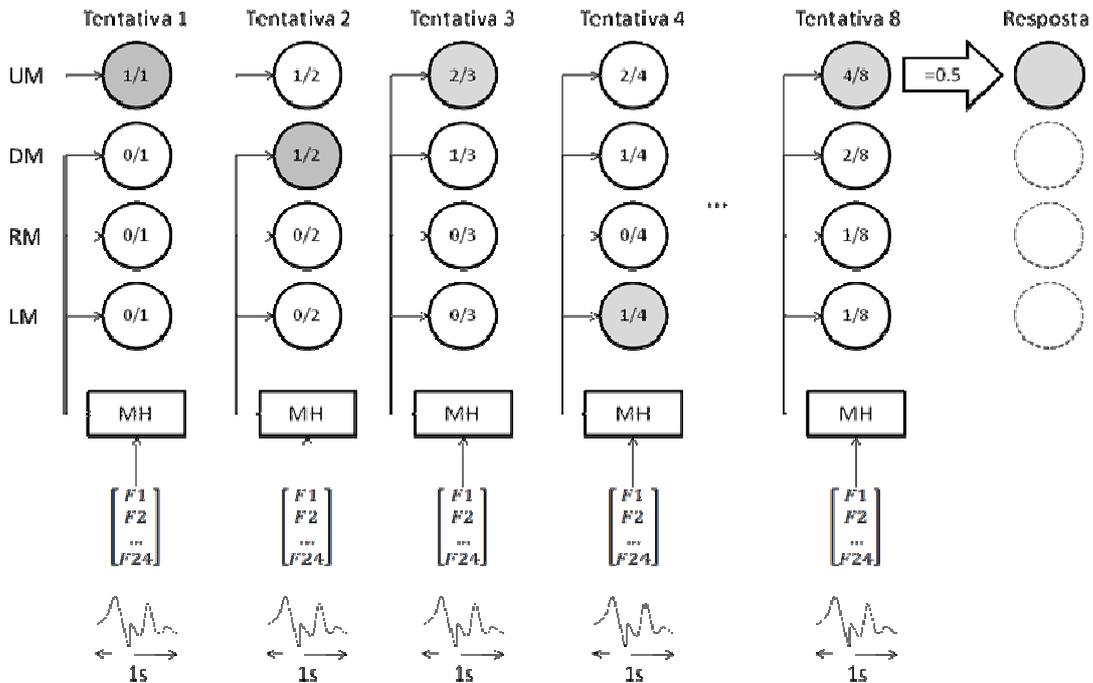


Figura 39 - Exemplo de implementação estatística.

Como dito anteriormente, artefatos podem ser considerados como eventos singulares e aleatórios nos sinais EEG. Dessa forma, numa aplicação com múltiplas classificações, a classificação de um sinal de uma atividade mental contaminado por um artefato não é estatisticamente relevante para a classificação final do sistema, tornando desnecessária a preocupação em detectar tal artefato.

No próximo capítulo, os algoritmos propostos são aplicados à BMI desenvolvida para movimentar um manipulador robótico.