

Prévision de charge dans un réseau électrique à l'aide du réseau de neurones de Kohonen

Autor(en): **Macabrey, Nicolas / Baumann, Thomas / Germond, Alain J.**

Objektyp: **Article**

Zeitschrift: **Bulletin des Schweizerischen Elektrotechnischen Vereins, des Verbandes Schweizerischer Elektrizitätsunternehmen = Bulletin de l'Association Suisse des Electriciens, de l'Association des Entreprises électriques suisses**

Band (Jahr): **83 (1992)**

Heft 5

PDF erstellt am: **22.07.2024**

Persistenter Link: <https://doi.org/10.5169/seals-902799>

Nutzungsbedingungen

Die ETH-Bibliothek ist Anbieterin der digitalisierten Zeitschriften. Sie besitzt keine Urheberrechte an den Inhalten der Zeitschriften. Die Rechte liegen in der Regel bei den Herausgebern.

Die auf der Plattform e-periodica veröffentlichten Dokumente stehen für nicht-kommerzielle Zwecke in Lehre und Forschung sowie für die private Nutzung frei zur Verfügung. Einzelne Dateien oder Ausdrucke aus diesem Angebot können zusammen mit diesen Nutzungsbedingungen und den korrekten Herkunftsbezeichnungen weitergegeben werden.

Das Veröffentlichen von Bildern in Print- und Online-Publikationen ist nur mit vorheriger Genehmigung der Rechteinhaber erlaubt. Die systematische Speicherung von Teilen des elektronischen Angebots auf anderen Servern bedarf ebenfalls des schriftlichen Einverständnisses der Rechteinhaber.

Haftungsausschluss

Alle Angaben erfolgen ohne Gewähr für Vollständigkeit oder Richtigkeit. Es wird keine Haftung übernommen für Schäden durch die Verwendung von Informationen aus diesem Online-Angebot oder durch das Fehlen von Informationen. Dies gilt auch für Inhalte Dritter, die über dieses Angebot zugänglich sind.

Prévision de charge dans un réseau électrique à l'aide du réseau de neurones de Kohonen

Nicolas Macabrey, Thomas Baumann, Alain J. Germond

Cet article présente une nouvelle approche pour la prévision à court terme de la charge d'un réseau électrique, avec application au réseau suisse romand pour les années 1984 et 1985, à l'aide du réseau de Kohonen. Après une brève rétrospective des travaux déjà effectués dans ce domaine, la nouvelle méthode est expliquée en détail. Les résultats obtenus à l'aide de la méthode proposée sont ensuite comparés à une méthode classique simple.

Dieser Artikel stellt eine neue Methode zur Voraussage der maximalen Last von elektrischen Netzen vor. Getestet wurde die auf der Basis von Kohonen-Netzwerken basierende Methode anhand von Daten des Westschweizer Netzes der Jahre 1984 und 1985. Nach einem kurzen Überblick über bisher auf diesem Gebiet geleistete Arbeiten wird die neue Methode erklärt. Die gewonnenen Resultate werden dann mit einer üblichen, einfachen Methode verglichen.

Adresse des auteurs

Nicolas Macabrey, ing. dipl. EPFL, Thomas Baumann, ing. dipl. EPFL, Prof. Dr. Alain J. Germond, Laboratoire de réseaux d'énergie électrique, Ecole Polytechnique Fédérale de Lausanne, 1015 Lausanne.

Une conception moderne des réseaux électriques nécessite, compte tenu du haut degré d'interconnexions et des coûts actuels de l'énergie, une excellente capacité de connaître la charge future d'une région donnée. On a défini la prévision de charge selon quatre catégories:

- très court terme: quelques minutes à une heure,
- court terme: quelques heures à une semaine,
- moyen terme: quelques semaines à quelques mois,
- long terme: jusqu'à dix ans.

La prévision de charge permet l'obtention d'informations utilisables dans le cadre de la planification des échanges d'énergie et de l'analyse de sécurité, en fournissant une détection à l'avance des éventuelles situations de vulnérabilité. Elle fournit également une aide à la programmation dynamique lors de l'établissement de l'optimum journalier ou hebdomadaire de la quantité d'énergie hydraulique assignée par la gestion mensuelle. La prévision de la charge fournit une aide à l'opérateur lorsqu'il dresse le plan de sa réserve tournante. De plus, il est des pays où une connaissance précise de la charge du lendemain permet d'éviter la coûteuse mise en route de centrales thermiques. Dans notre pays, le besoin d'une bonne prévision est plus particulièrement sensible les jours de semaine lorsque la demande est forte. La prévision à une décennie permet enfin d'adapter le parc de production de la réserve tournante. Cet article propose une méthode originale de prévision de la charge de pointe du lendemain du jour considéré, utilisant le réseau de neurones artificiels de Kohonen.

Deux méthodes de prévision de la charge et classification

Si au cours de ces dernières décennies l'importance de la prévision s'est faite plus cruciale, les techniques, de leur côté, se sont affinées en ayant recours à des modèles de plus en plus évolués. L'approche du problème par les réseaux de neurones n'est qu'une nouvelle étape d'un processus qui, entre autres, se manifesta dès les années 1940 par un vif intérêt pour la corrélation existant entre les conditions météorologiques et la charge électrique. Il existe ainsi deux approches de la prévision, l'une classique, l'autre résolument nouvelle par l'utilisation des réseaux neuronaux. Ces deux méthodologies nécessitent souvent des outils tels que la classification et la caractérisation de la charge.

Il peut être important dans certaines régions de classer les consommateurs selon quatre catégories: résidentielle, commerciale, industrielle et utilisateurs particuliers tel l'éclairage public ou les chemins de fer. Malheureusement, il est rare que les classifications soient mutuellement exclusives.

Parmi les trois groupes principaux d'utilisateurs cités ci-dessus, les résidents ont le taux de croissance annuel le plus stable ainsi que les fluctuations saisonnières les plus marquées. Le profil de la charge du secteur commercial, compte tenu du désir d'une température constante à l'intérieur des locaux, présente lui aussi une tendance saisonnière, bien que moins nette que dans le cas des résidents. Le secteur industriel montre une corrélation avec le niveau de production, lui-même reflet de la situation économique.

Les méthodes classiques

On peut diviser les méthodologies classiques de la prévision en quatre classes principales: extrapolation, corrélation, séries temporelles et régression [1]. Ce classement peut être poursuivi par une mise en exergue du caractère déterministe, probabiliste ou stochastique de la méthode.

Extrapolation: ces techniques tentent d'ajuster des courbes de tendance aux données historiques de la charge afin de refléter la tendance elle-même. La prévision est obtenue grâce à une évaluation de la courbe de tendance par des fonctions analytiques standard au point désiré. Il s'agit dans ce cas d'une extrapolation déterministe.

Corrélation: les techniques corrélatives introduisent dans le modèle de charge une correspondance entre des facteurs de type économique, météorologique ou démographique et le profil de la consommation. Leur principal désavantage réside dans la difficulté d'établissement de ces facteurs.

Les séries temporelles: l'idée d'une approche par séries temporelles est induite par la nature du modèle de la charge qui est très proche d'un signal temporel avec une période saisonnière, hebdomadaire ou journalière. Le caractère stochastique du signal réel est traité par des méthodes d'analyse des signaux aléatoires. Malheureusement, cette approche supporte mal les modifications abruptes des variables environnementales agissant sur la charge et nécessite, de plus, d'importants temps de calcul.

Régressions: la procédure d'approche par régression consiste en premier lieu à trouver des variables adéquates (par

exemple: des variables météorologiques). On recherche ensuite des fonctions de base, souvent simplement constituées de fonctions linéaires ou linéaires par morceaux et on détermine enfin des coefficients appropriés à une combinaison linéaire de ces fonctions de base.

Introduction aux réseaux de neurones artificiels

L'informatique actuelle est totalement basée sur le principe de la machine séquentielle de von Neumann. Malheureusement, la nature purement déterministe de cet outil lui rend inaccessible toute une série d'actions élémentaires, telle la reconnaissance de formes.

Si le cerveau a été de tous temps un sujet de réflexion pour l'homme, il faut attendre 1943 pour voir naître, au travers d'une étude de McCulloch et Pitts, l'intérêt pour les réseaux neuronaux. Ces réseaux présentent une alternative à l'accroissement de la complexité des modèles du calcul formel en proposant la solution de l'apprentissage par l'exemple sur une structure massivement parallèle. Le parallélisme, qui permet d'atteindre des vitesses de traitement d'informations très importantes par l'exploration simultanée d'hypothèses concurrentes, n'est pas le seul attrait des réseaux neuronaux. Du recours très large à une distribution, à la fois de l'information et de son traitement dans des processeurs élémentaires, résulte une plus grande robustesse vis-à-vis du dysfonctionnement d'un petit nombre d'éléments. La découverte d'une solution ne sera plus ici un processus pré-

visible et quantifiable de manière déterministe mais plutôt l'effet de l'émergence d'une tendance. Ce caractère révélera une sensibilité particulièrement faible aux bruits spoliant les signaux d'entrée.

Si la localisation du calcul dans un grand nombre de processeurs élémentaires réalisant des tâches simples permet une diminution de la complexité de ces unités, elle augmente, par contre, la quantité d'information à échanger entre unités. Ce point risque d'être le talon d'Achille des réseaux de neurones.

Il faut noter encore que les réseaux neuronaux basés sur un modèle connexionniste s'inspirent d'une connaissance des cellules nerveuses datant d'une cinquantaine d'années ce qui laisse présager de développements prometteurs [2].

Une taxonomie des réseaux de neurones

Il existe, déjà actuellement, un nombre important d'architectures différentes de réseaux de neurones parmi lesquelles il faudra choisir la plus apte à accomplir une tâche particulière [3; 4]. La fonction d'un réseau est déterminée par des caractéristiques comme la topologie des connexions entre les unités, l'intensité de ces connexions, le type de traitement effectué dans chaque unité ou encore le mode et les règles d'apprentissage. Ces différentes caractéristiques peuvent composer les critères d'une taxonomie.

On a séparé les modèles principaux d'après le caractère de la phase d'apprentissage en différenciant les réseaux à apprentissage supervisé et non supervisé (fig. 1). La méthode d'adaptation dite supervisée suppose durant la phase d'apprentissage la présence des vraies valeurs de sortie, permettant une adaptation contrôlée des poids d'interconnexions afin d'atteindre, en sortie, un optimum que l'on choisit aussi proche que possible de la vraie valeur désirée. Contrairement à cette première méthode, les réseaux neuronaux non supervisés s'organisent uniquement en fonction des entrées. Ce type de réseau est utilisé pour la quantification d'un espace d'entrée ainsi que pour un regroupement des données selon un critère interne, propre au réseau choisi. On fournit au réseau neuronal un ensemble de vecteurs, dont il doit par lui-même découvrir les caractéristiques et régularités.

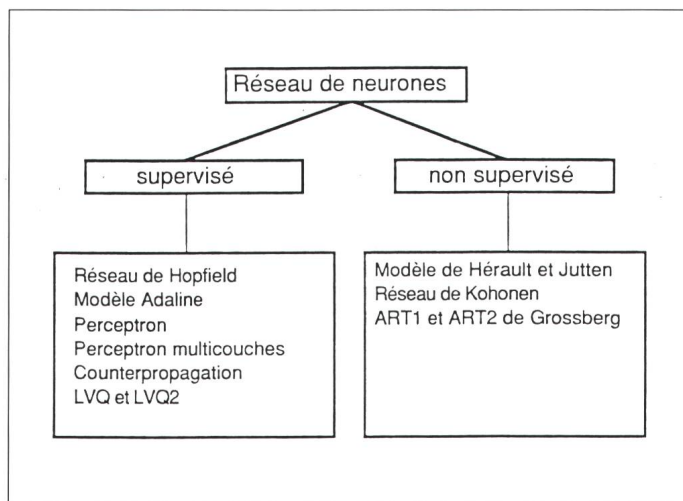


Figure 1
Taxonomie des réseaux de neurones




Figure 2 Le processeur élémentaire ou neurone artificiel

Premières applications des réseaux de neurones à la prévision de charge

Ce paragraphe présente les méthodes et les résultats enregistrés lors des premières applications connues de réseaux de neurones à la prévision de charge. L'étude originelle en la matière est l'œuvre de T.S. Dillon [5] qui a réalisé une prévision de charge en développant des méthodes d'auto-organisation et de reconnaissance de formes de caractère non supervisé. Deux travaux plus récents ont eu recours à un réseau de neurones de type Perceptron multi-couches travaillant avec un algorithme d'apprentissage appelé rétro-propagation du gradient. Le premier de ces travaux, qui ne tenait pas compte des données météorologiques s'est déroulé en Corée [6]. Il y fut décidé d'appliquer deux méthodes différentes: l'une statique, fournissant une prévision simultanée des 24 charges horaires à venir, l'autre dynamique, trouvant les 24 charges horaires à venir de manière séquentielle en utilisant les prévisions des charges horaires précédentes. Les résultats montrent une erreur relative de prévision oscillant entre 1 et 2,7% dans les deux cas, bien que la taille du réseau de la deuxième méthode fût nettement moindre.

La seconde étude, qui intégrait la température, fut menée dans l'état de Washington au Nord-Ouest des Etats-Unis [1] sur la base des données de la charge électrique et de la température pour la zone de Seattle entre le 1^{er} novembre 1988 et le 30 janvier 1989.

Les réalisateurs ont fixé leur attention uniquement sur les jours de semaine normaux.

L'intérêt s'est porté sur les types de prévision suivants: charge de pointe du lendemain, charge totale du lendemain et charge horaire n heures à l'avance. Les effets de cette période de n heures sur la précision ont été testés en faisant varier la dite période de 1 à 24 heures avec des intervalles de 3 heures. On s'est alors aperçu que l'erreur augmentait graduellement à mesure que la période croissait, pour atteindre un maximum de 2,79% après 18 heures.

Deux articles [7; 8], parus depuis la réalisation du présent projet, décrivent une solution qui utilise un réseau de Kohonen pour classer le type de jour, et un réseau multicouche pour évaluer la charge du lendemain.

Le réseau de Kohonen

Une propriété intéressante du cerveau, qui a toujours été ignorée dans les machines à apprentissage, est constituée par un ordre significatif des unités de processus. Il faut d'emblée remarquer que cet ordre se réalise sans déplacement physique des neurones mais par modification des paramètres internes.

Bien qu'une part de cette organisation à l'intérieur du cerveau soit déterminée génétiquement, il est intrigant d'apprendre qu'un ordre spatial presque optimal, en relation avec les statistiques des signaux d'entrée, peut être déterminé dans de simples processus d'auto-organisation sous le contrôle de l'information reçue. Il semble qu'un tel ordre spatial soit nécessaire pour une représentation efficace de l'information dans les modèles internes du cerveau.

Dans le cortex par exemple, les zones réceptrices sont ordonnées d'une manière identique à celle des unités de l'organe sensoriel lui-même. Il existe ainsi une correspondance topologique entre ces zones. Par exemple, deux zones proches dans le cortex visuel correspondent à deux zones également proches dans la rétine.

En 1982, Teuvo Kohonen [9] propose un nouveau modèle de réseau de neurones, qui paraît capable de simuler les observations biologiques décrites plus haut. Un réseau de neurones peut être caractérisé comme un ensemble de processeurs élémentaires, aussi appelés neurones artificiels, qui exécutent tous la même

tâche en parallèle. L'information à traiter est distribuée par des connexions unidirectionnelles sur tous les processeurs élémentaires.

La figure 2 montre le schéma d'un processeur élémentaire (PE) où chaque entrée E_j est reliée au PE par un poids synaptique W_j . Ces derniers peuvent être comparés à la conductance d'un fil électrique. Les composantes de E_j et W_j forment d'une part le vecteur d'entrée \vec{E} et d'autre part le vecteur de poids synaptiques \vec{W} .

Pour la plupart des réseaux de neurones, l'opération entre \vec{E} et \vec{W} pour calculer la sortie S est le produit scalaire. Pour l'algorithme de Kohonen, l'opération élémentaire est la distance Euclidienne, soit:

$$S = D_{\text{Eucl}} = \sqrt{\sum_{j=1}^N (E_j - W_j)^2} \quad (1)$$

où N est le nombre d'entrées.

L'architecture de base du modèle de Kohonen est composé d'une couche de N entrées suivie d'une couche de $M \cdot M$ neurones, arrangés selon une grille bi-dimensionnelle. Chaque entrée est reliée par une connexion synaptique W_{ij} à tous les neurones de la deuxième couche (fig. 3).

Il est bon de rappeler que, contrairement aux logiciels classiques programmés selon une suite séquentielle d'instructions, les réseaux neuronaux fonctionnent sur la base d'un apprentissage. En d'autres termes, on ne programme plus une loi, mais on enseigne au réseau neuronal par l'exemple. Cette technique peut donc être inté-

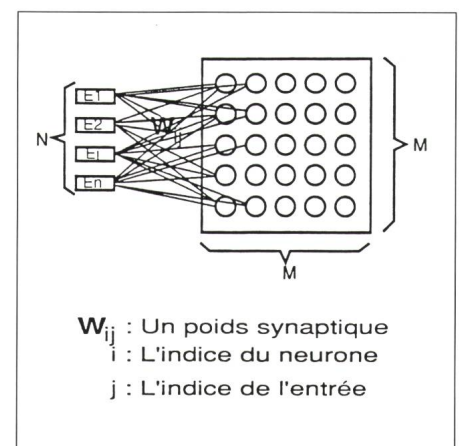


Figure 3 L'architecture de base du réseau de Kohonen

Pour des raisons de lisibilité les connexions ne sont pas représentées

ressante dans des cas où une loi n'est que peu ou pas connue, ce qui est le cas pour la prévision de charge.

L'apprentissage des réseaux neuro-naux se fait par modification continue des poids synaptiques W_{ij} suivant une règle interne propre à chaque type de réseau neuronal. Cela nécessite une présentation répétée des vecteurs d'entrée, jusqu'à l'obtention d'une organisation suffisante du réseau. Un pas d'apprentissage comprend deux phases [10]:

Phase 1: trouver le neurone dont le vecteur poids W_c est le plus proche du vecteur d'entrée E

On présente un vecteur d'entrée E au réseau de Kohonen et on calcule la distance Euclidienne entre ce vecteur et tous les vecteurs poids W_i . On a ainsi déterminé une distance Euclidienne pour chaque neurone. Le neurone dont la distance Euclidienne est minimale est le neurone gagnant. Ce neurone d'indice c contient donc le vecteur poids W_c , le plus proche du vecteur d'entrée présenté.

Phase 2: adaptation des poids synaptiques du neurone d'indice c et de ses voisins

Une fois ce nœud c repéré, on modifie la valeur des poids des connexions le liant aux entrées. Cette modification a lieu également pour les neurones situés dans le voisinage N_c du neurone vainqueur c . Pour les autres neurones, exclus du voisinage, les valeurs des poids ne varient pas. L'adaptation des poids synaptiques est donc effectuée de la manière suivante:

$$W_i(t+1) = W_i(t) + \alpha(t) * (X(t) - W_i(t))$$

pour $i \in N_c$

$$W_i(t+1) = W_i(t)$$

pour $i \notin N_c$

(2)

où $\alpha(t)$ est le gain d'apprentissage ($0 < \alpha(t) < 1$) qui décroît avec le pas d'apprentissage.

On peut remarquer que la loi d'adaptation des poids synaptiques ne fait que rapprocher les vecteurs poids du neurone c et ses voisins du vecteur d'entrée. Au début, le rayon du voisinage d'apprentissage N_c est grand (environ la moitié de la taille du réseau) et décroît ensuite avec le pas d'apprentissage jusqu'à ce qu'il atteigne zéro. Si le rayon est zéro, alors il n'y a que les poids du neurone vainqueur




Figure 4 Evolution du rayon de voisinage d'apprentissage N_c autour du neurone vainqueur avec le temps (en une dimension)

qui sont modifiés (fig. 4). Le fait que l'on modifie non seulement les poids du neurone gagnant, mais aussi les poids des neurones voisins, entraîne l'auto-organisation du réseau [10].

En résumé, il existe des cartes bi-dimensionnelles qui sont capables de préserver les relations topologiques en effectuant une réduction de la dimension de l'espace d'entrée. Ces cartes possèdent en plus la propriété de partitionner un espace d'entrée en M^2 sous-espaces, aussi appelés «zones d'influence», déterminés par l'ensemble des vecteurs d'entrée qui font gagner le même neurone.

Le réseau de Kohonen a été appliqué à la prévision de séries non-linéaires [11], ainsi qu'à des problèmes de diagnostic de défaut [12] et d'analyse de sécurité des réseaux électriques [13].

Application du réseau de Kohonen à l'auto-association

Une fois l'apprentissage achevé, la présentation d'un vecteur incomplet suffit au réseau de Kohonen pour re-

trouver les composantes manquantes. Cette méthode est connue sous le nom d'auto-association. Exemple: lorsque le réseau a été organisé avec un ensemble d'images sous forme binaire, il lui sera possible de reconstituer l'image originale à partir d'une image partiellement connue [10].

La technique consiste à ignorer les composantes inconnues du vecteur d'entrée incomplet et calculer la distance Euclidienne pour le reste du vecteur d'entrée. On sélectionnera alors, comme dans le cas normal, le neurone avec la distance minimum. Le poids porté par la connexion entre ce neurone vainqueur et toutes les entrées ignorées sont les valeurs des sorties cherchées (fig. 5).

Application à la prévision de charge

Dans ce paragraphe on présentera l'application du réseau de Kohonen à la prévision de la charge de pointe, avec l'application au réseau suisse romand. Ce type de réseau à apprentissage non supervisé se prête particulièrement bien à cette tâche par sa propriété d'extraction des caractéristiques principales des vecteurs d'entrée. Pendant cette extraction le réseau de Kohonen crée automatiquement un nombre fixe de vecteurs de référence qui correspondent tous à un jour type contenu dans la période d'apprentissage. Le nombre maximum de jours de référence est fixé par le nombre de neurones.

La base de données

On présente ici les éléments qui constituent entièrement ou partielle-

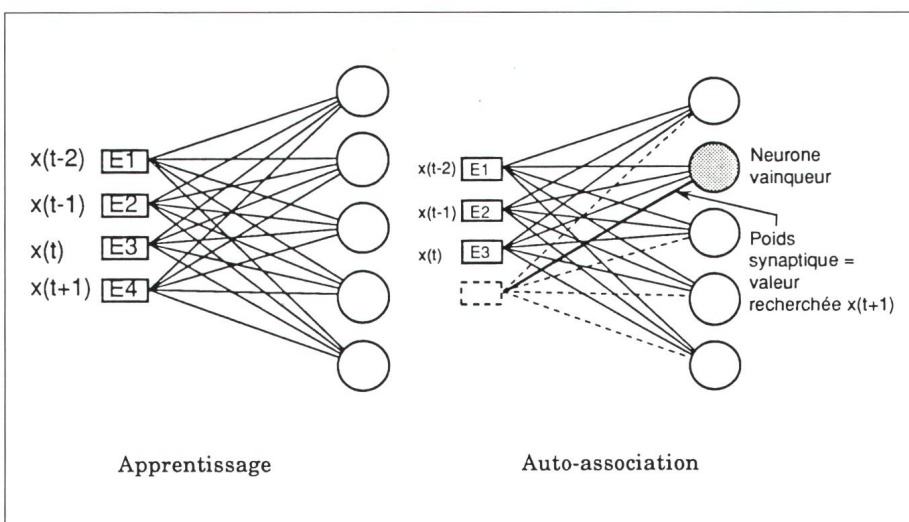


Figure 5 Principe de l'auto-association

ment la base de données au cours des essais:

Les 24 charges horaires: les charges considérées dans cette étude sont les charges de consommation moyenne horaire du 1^{er} octobre 1984 au 30 septembre 1986 des réseaux des cantons de Fribourg, Vaud et Genève (les sociétés CVE, EEF, SEL, SIG et SRE) qui ont été transformées linéairement pour banaliser les données.

Les données météorologiques: l'institut de météorologie de Genève-Cointrin nous a fait parvenir la température moyenne journalière et le taux de couverture nuageuse journalier de Genève pour la période citée auparavant.

Le calendrier: définition du jour du lendemain (lundi, mardi, etc.). Dans cet article, les jours spéciaux, tels que Noël ou Pâques, ne seront pas considérés pour la prévision.




Figure 6 Définition du vecteur d'entrée

La charge de pointe du lendemain: il s'agit de la valeur à prévoir, mais elle fait partie du vecteur d'entrée lors de l'apprentissage.

Les données ont été séparées en deux parties de mêmes durées, la première du 1^{er} octobre 1984 au 30 septembre 1985 jouant le rôle de données d'apprentissage du réseau de Kohonen, alors que celles allant du 1^{er} octobre 1985 au 30 septembre 1986 devenaient les données de test pour évaluer les performances de la méthode. Par la suite on appelle les deux bases de données 1984 et 1985.

Résultats des essais sans données météorologiques

Dans les tâches de prévision (et de classification), on rencontre toujours deux problèmes importants, à savoir la définition du vecteur d'entrée et son prétraitement. Malheureusement il




Figure 7 Organisation d'un réseau de Kohonen après l'apprentissage

n'existe pas de méthodes générales qui peuvent résoudre ces deux problèmes et on est contraint de trouver les paramètres adéquats par essais successifs. On a divisé nos essais en deux groupes, celui qui néglige les données météorologiques et celui qui ne les néglige pas.

Après quelques essais, on a retenu un vecteur d'entrée qui est composé de trois groupes et totalise 29 composantes (fig. 6). Les 24 premières composantes du vecteur d'entrée contiennent les charges du jour j . On définit ensuite la position du jour $j + 1$ dans la semaine selon le nombre de classes affecté à sa définition. On a choisi d'utiliser quatre classes, comme indiqué dans la figure 6. Un mardi formera par exemple le vecteur (0,1,0,0). La dernière composante contient la charge de midi du jour $j + 1$, donc la valeur recherchée. Cette valeur fait partie du vecteur d'entrée lors de l'apprentissage. Par contre c'est la valeur à prévoir lors de la phase d'auto-association.

On a réduit le problème du prétraitement au choix des pondérations des composantes des vecteurs d'entrée. La variance d'une composante, calculée sur tous les vecteurs, détermine l'influence de celle-ci sur le calcul du neurone gagnant. Cette influence croît avec la variance. Il faut donc trouver les facteurs appropriés de pondération. De nombreux essais ont montré qu'il suffit de choisir les facteurs de pondération de telle sorte que les variances des composantes contenant la définition du jour soient environ dix fois plus grandes que les autres variances.

Après avoir défini le vecteur d'entrée et son prétraitement, on effectue

un apprentissage du réseau de Kohonen avec les 365 vecteurs de la base de données 1984 (1^{er} octobre 1984 au 30 septembre 1985). Après cela, chaque neurone contient un vecteur poids qui devient un vecteur de référence. Tous les neurones se spécialisent donc pour un certain profil de charge et de jour. La figure 7 montre pour quel jour et pour quelle période de la base de données 1984 les neurones d'un réseau de dimension 10×10 se sont spécialisés après 25000 pas d'apprentissage. Cela est fait en cherchant pour chaque vecteur de la base 1984 le plus proche vecteur poids.

On distingue quatre régions qui correspondent aux quatre classes de jours. Elles sont séparées par des interneurones, qui contiennent un mélange de deux classes de jours. L'explication de ce phénomène sortirait du cadre de cet article. On peut séparer de plus chacune de ces régions en trois périodes dans l'année, soit l'été, l'hiver et, à cause du profil de charge similaire, une période comprenant le printemps et l'automne. Cette formation de régions découle de la propriété de conservation de la topologie des vecteurs d'entrée.

La charge maximale du lendemain peut être trouvée par la méthode d'auto-association expliquée auparavant. Dans notre cas, on utilise pour l'évaluation des jours pris dans la période du 1^{er} octobre 1985 au 30 septembre 1986, qui forment la base de données de test. On présente donc un vecteur de la base de données de test sans la composante n° 29, c'est-à-dire sans la composante qui contient la valeur recherchée. On calcule le neurone gagnant, et la connexion reliant celui-ci à l'entrée 29 est la réponse cherchée.

Le tableau I montre quelques définitions d'erreurs. On est malheureusement contraint d'indiquer toutes les mesures sous forme relative, parce qu'on ne disposait pas des charges absolues. Le paramètre qui influence le plus les résultats obtenus est la taille du réseau de Kohonen. Le tableau II montre les trois types de mesures en fonction de la taille. On remarque que les trois mesures d'erreur diminuent avec le nombre de neurones. La mesure de l'erreur relative moyenne (ERM) reflète l'augmentation annuelle de la charge. On constate que nos prévisions sont donc en moyenne un peu trop basses par rapport à la valeur désirée. Une discussion des causes de ce phénomène et les possibilités d'améliorer la prévision seront données plus tard. Afin d'obtenir une représentation parlante de l'évolution

Tableau I

Définitions d'erreurs
 E est l'espérance, d_i la valeur de la charge du jour suivant à midi, selon la base de données de test, et r_i la valeur obtenue par auto-association

Erreur relative:	$e_{r,i} = (d_i - r_i) / d_i$
Erreur relative moyenne :	$\mu_r = E (e_{r,i})$
Ecart-type relatif :	$\sigma_r = (E ((e_{r,i} - \mu_r)^2))^{1/2}$
Erreur relative moyenne des valeurs absolues:	$\mu_{r,Abs} = E (abs(e_{r,i}))$

données météo s'est révélée un peu meilleure. On peut interpréter ces résultats en comprenant que les données météo sont déjà comprises partiellement dans les 24 charges horaires du jour et que de ce fait elles n'amènent une amélioration que dans des cas particuliers, lorsque la température connaît une très forte variation sur un laps de temps court. C'est peut-être la raison de la diminution des erreurs

mentation. Une manière plus simple à laquelle on a songé, fut d'intégrer les nouveaux jours dans la base de données au fur et à mesure de leur disponibilité. Cela pourrait être fait par exemple toutes les semaines. Après chaque modification de la base de données il faudra évidemment refaire un apprentissage complet. Par le fait qu'avec les simulateurs de réseaux de neurones actuels, l'apprentissage peut prendre quelques dizaines de minutes, l'évaluation de cette méthode pour toute une année aurait pris trop de temps.

La deuxième approche consiste à introduire un facteur d'augmentation de la charge (erreur relative moyenne). Il est évident qu'en travaillant de cette manière, on a admis l'hypothèse d'une translation du profil de la charge entre les deux années d'évaluation. Ce facteur d'augmentation peut être déterminé pour le passé et ensuite extrapolé pour le futur. Par cette approche, l'erreur relative diminue de 2,81% à 2,58% dans notre cas. Cette différence relativement faible est due à une variance non négligeable des erreurs. Une troisième méthode utilise des vecteurs qui reflètent les changements de la charge par rapport au jour précédent. Ainsi, l'erreur due à l'augmentation de la charge annuelle peut être éliminée.

Nb de Neurones	ERM [%]	ERMA [%]	Ecart-type rel [%]
7,7	1,93	3,366	4,00
10,10	1,58	3,067	3,72
15,15	1,51	2,998	3,61
20,20	1,44	2,938	3,58
25,25	1,40	2,838	3,45
30,30	1,37	2,814	3,43

Tableau II
Erreur relative moyenne ERM, erreur relative moyenne des valeurs absolues ERMA et écart-type relatif en fonction de la taille du réseau de Kohonen

des erreurs de prévision relatives au cours de la période d'évaluation, il est possible de représenter un graphe de ces erreurs (fig. 8).

La courbe aux amplitudes les plus importantes présente les erreurs pour chaque jour de l'évaluation, alors que celle aux accents plus doux est une moyenne en chaque jour des vingt valeurs temporelles les plus proches. Cette seconde courbe est plus révélatrice de la tendance temporelle. Cette représentation indique également l'erreur maximale qui est d'environ 14%. On peut également tracer un histogramme des erreurs relatives qui révèle la dispersion de ces erreurs autour d'une moyenne (fig. 9).

Simulations avec données météorologiques

Nous avons constaté que la conservation de la température comme unique donnée météorologique présentait l'avantage de réduire la complexité du problème. Dans ces conditions, l'erreur moyenne entre les versions avec et sans données météo était pratiquement équivalente. Dans le cas de l'erreur maximum, la version avec

maximum lorsque l'on utilise la température.

La progression annuelle de la charge

On s'est enfin interrogé sur la manière de tenir compte de la croissance annuelle de la consommation énergétique. Il est entendu qu'avec une phase d'apprentissage d'une durée d'une année, il est impossible au réseau de neurones d'intégrer cette aug-




Figure 8 L'erreur relative en fonction du temps, du 1^{er} octobre 1985 au 30 septembre 1986 pour un réseau de 30 x 30 neurones

Conclusion

A l'aide de la méthode présentée dans cet article, la prévision de la charge journalière peut être encore affinée, en vue d'une meilleure gestion de l'énergie électrique. A titre comparatif, on a confronté nos résultats à une méthode de prévision souvent utilisée en Suisse. Cette dernière consiste à prendre les charges du jour précédent pour les jours de semaine sauf pour le lundi. Pour le lundi, on prend la charge du vendredi précédent, et pour le samedi et le dimanche, les charges du même jour de la semaine précédente. Avec cette méthode, on obtient une erreur moyenne absolue de 3,13% de la charge totale (2,81% avec la méthode de Kohonen). Notre méthode est par conséquent supérieure à celle appliquée habituelle-

ment en Suisse. Par contre, elle ne tient pas compte de la croissance annuelle de la charge (par définition).

Les résultats présentés dans cet article sont moins bons que ceux cités dans [1, 6]. Mais il faut noter que le réseau suisse romand est environ cinq fois plus petit que ceux précités. Nos charges relatives sont donc soumises à des fluctuations journalières plus importantes.

Remerciements

Nous remercions MM. Sorin Birstein et Yves Jaccard de la S.A. l'Énergie de l'Ouest Suisse (EOS) de leur précieuse collaboration. La recherche présentée dans cet article a été financée par le Fonds National Suisse de la Recherche Scientifique, Projet n° 20-26557.89.

Bibliographie

- [1] Park D.C., El-Sharkawi M.A., Marks II R.J. et al.: Electric Load Forecasting Using An Artificial Neural Network. IEEE, Transactions on Power Systems, Vol. 6, No. 2, pp. 442-449, May 1991.
- [2] Bernasconi J.: Neurale Netzwerke: Theorie und Praxis. Bulletin SEV/VSE 80(1989)13, pp. 11-16.
- [3] Lippmann R.P.: An Introduction to Computing with Neural Nets. IEEE ASSP Magazine, pp. 4-21, April 1987.
- [4] Leber J.F., Matthews M.B.: Neurale Netzwerke: eine Übersicht. Bulletin SEV/VSE 80(1989)15, pp. 923-932.
- [5] Dillon T.S., Morsztyn K., Phua K.: Short Term Load Forecasting Using Adaptive Pattern Recognition and Self-Organizing Techniques. Proc. of Fifth Power Systems Computation Conference, Cambridge, Paper 2.4/3, pp. 1-16, 1975.
- [6] Lee K.Y., Cha Y.T., Park J.H.: Short-Term Load Forecasting Using an Artificial Neural Network. IEEE, PWRs Winter Meeting 199-0, 1991.
- [7] Hsu Y.-Y., Yang C.-C.: Design of Artificial Neural Networks for Short-term Load Forecasting. Part I: Self-organising Feature Maps for Day Type Identification. IEE Proceedings-C, 138(1991)5, pp. 407-413.
- [8] Hsu Y.-Y., Yang C.-C.: Design of Artificial Neural Networks for Short-term Load Forecasting. Part II: Multilayer Feedforward Networks for Peak Load and Valley Load Forecasting. IEE Proceedings-C, 138(1991)5, pp. 414-418.
- [9] Kohonen T.: Self-Organized Formation of Topologically Correct Feature Map. Biological Cybernetics, 43(1982) pp. 59-69, Springer-Verlag.
- [10] Kohonen T.: Self-Organization and Associative Memory. 2nd edition, Springer Verlag, New York, 1988.
- [11] Walter J., Ritter H., Schulten K.: Non-Linear Prediction with Self-Organizing Maps. Proc. IEEE International Conference on Neural Networks, San Diego, Cal., 1(1990) pp. 589-594.
- [12] T. Baumann, A.J. Germond, D. Tschudi: „Impulse Test Fault Diagnosis on Power Transformers using Kohonen's Self-Organizing Neural Network“. Proc. of ESAP 91, Tokyo, April 1991, pp. 642-647.
- [13] D. Niebur, A.J. Germond: „Power System Static Security Assessment Using the Kohonen Neural Network Classifier“, Proc. of the IEEE Power Industry Computer Application Conference, Baltimore, May 1991, pp. 270-277.






Figure 9
Histogramme des erreurs relatives pour un réseau de 30 x 30 neurones




Sie arbeiten in verschiedenen Branchen, aber gemeinsam für...



Ein Entwicklungsingenieur aus der Kühlmöbelindustrie und ein Werkstoffingenieur von BASF stimmen überein: Die enge Zusammenarbeit hat sich gelohnt. Sowohl bei den Lacken und Harzen für die Motorisolierung, den Werkstoffen für die Innenausstattung als auch bei den umweltschonenden PUR-Hartschaumsystemen und Lacken für die Oberflächenbeschichtung befinden sich die aktuellen Typenreihen auf dem neuesten Stand der Technik.

Die Ansprüche an die elektrotechnische Industrie – weitere Miniaturisierung und höher Integration, extreme Belastbarkeit der Produkte, Sicherheit, Ergonomie und Wirtschaftlichkeit – fordern eine immer engere Kooperation zwischen dieser Branche und ihren Zulieferern.

Was wir einbringen: Denken in Systemlösungen und Alternativen, Bauteilkonstruktion



iedenen Firmen – rne Haushaltsgeräte.

vicklungskooperation mit Hersteller und
ferern, weltweite Präsenz.
Und dies auf der Basis eines breiten Pro-
angebots, das auf die aktuellen Anfor-
ngen der elektrotechnischen Industrie
schnitten ist. Von Kunst- und Werkstof-
über Produkte für die Chip-Produktion bis
zu Chemikalien für die Herstellung von
thermedien sowie Farbmitteln für die un-
chiedlichsten Einsatzbereiche.

**Aufgaben sind der Maßstab unse-
Arbeit – internationales Engagement
die elektrotechnische Industrie.**



Ich bin daran interessiert, in Zukunft über das breite Engagement der BASF für die elektrotechnische Industrie informiert zu werden.

Name/Firma


Straße

PLZ/Ort

Telefon

Funktion/Beruf

BASF (Schweiz) AG, Postfach 99, CH-8820 Wädenswil/Au.
Tel.: 01/7 81 91 11, Fax: 01/7 81 93 88.



Schweizerischer Elektrotechnischer Verein
Association Suisse des Electriciens
Associazione Svizzera degli Elettrotecnici
Swiss Electrotechnical Association



Wirksame Blitzschutzanlagen



Blitzschutzanlagen sind nicht billig. Sie können sogar teuer zu stehen kommen, wenn unsachgemäss geplant und ausgeführt, denn nachträgliche Änderungen sind immer mit hohen Kosten verbunden. Zudem besteht die Gefahr, dass derartige Anlagen im Ernstfall ihren Zweck nicht erfüllen.

Wir kennen die Probleme des Blitzschutzes und die optimalen Lösungen hierfür.

Wir stehen Privaten, Ingenieurunternehmen und kantonalen Instanzen zur Verfügung für Planung, Beratung, Kontrollen, Branduntersuchungen und Instruktionkurse.

Auskunft: Schweizerischer Elektrotechnischer Verein, Starkstrominspektorat
Seefeldstrasse 301, Postfach, 8034 Zürich
Telefon 01/384 91 11 – Telex 817431 – Telefax 01/55 14 26